

**İLERİ İSTATİSTİKSEL YÖNTEMLER KULLANARAK
RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN
TAHMİNİ**

**WIND-ELECTRIC POWER FORECAST USING
ADVANCED STATISTICAL METHODS**

SERKAN BUHAN

Prof. Dr. İŞİK ÇADIRCI

Tez Danışmanı

Hacettepe Üniversitesi

Lisansüstü Eğitim – Öğretim ve Sınav Yönetmeliğinin

Elektrik ve Elektronik Mühendisliği Anabilim Dalı için Öngördüğü

DOKTORA TEZİ olarak hazırlanmıştır.

2015

SERKAN BUHAN' ın hazırladığı “**İleri İstatistiksel Yöntemler Kullanarak Rüzgârdan Üretilen Elektriksel Gücün Tahmini**” adlı bu çalışma aşağıdaki jüri tarafından **ELEKTRİK VE ELEKTRONİK MÜHENDİSLİĞİ ANABİLİM DALI'** nda **DOKTORA TEZİ** olarak kabul edilmiştir.

Prof. Dr. Muammer ERMİŞ

Başkan

Prof. Dr. Işık ÇADIRCI

Danışman

Doç. Dr. Özgül SALOR DURNA

Üye

Yrd. Doç. Dr. Yakup ÖZKAZANÇ

Üye

Yrd. Doç. Dr. Seniha Esen YÜKSEL

Üye

Bu tez Hacettepe Üniversitesi Fen Bilimleri Enstitüsü tarafından **DOKTORA TEZİ** olarak onaylanmıştır.

Prof. Dr. Fatma SEVİN DÜZ

Fen Bilimleri Enstitüsü Müdürü

eşime ve kızıma...

ETİK

Hacettepe Üniversitesi Fen Bilimleri Enstitüsü, tez yazım kurallarına uygun olarak hazırladığım bu tez çalışmada,

- tez içindeki bütün bilgi ve belgeleri akademik kurallar çerçevesinde elde ettiğimi,
- görsel, işitsel ve yazılı tüm bilgi ve sonuçları bilimsel ahlak kurallarına uygun olarak sunduğumu,
- başkalarının eserlerinden yararlanılması durumunda ilgili eserlere bilimsel normlara uygun olarak atıfta bulunduğumu,
- atıfta bulunduğum eserlerin tümünü kaynak olarak gösterdiğimi,
- kullanılan verilerde herhangi bir değişiklik yapmadığımı,
- ve bu tezin herhangi bir bölümünü bu üniversite veya başka bir üniversitede başka bir tez çalışması olarak sunmadığımı

beyan ederim

... / ... / 2015

SERKAN BUHAN

ÖZET

İLERİ İSTATİSTİKSEL YÖNTEMLER KULLANARAK RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN TAHMİNİ

Serkan BUHAN

Doktora, Elektrik ve Elektronik Mühendisliği Bölümü

Tez Danışmanı: Prof. Dr. Işık ÇADIRCI

Aralık 2015, 100 sayfa

Bu tez çalışması, çok katmanlı ileri istatistiksel yöntemler kullanarak rüzgârdan üretilen elektriksel gücün kısa dönemli tahminini yapmayı ve rüzgâr gözlem istasyonlarının (RWM) ölçüm verileri ile sayısal hava tahmin modellerinin (NWP) verileri arasında korelasyon kurarak ve rüzgâr örüntü tanıma teknikleri kullanarak tahminlerin iyileştirilmesini amaçlamaktadır. Bu çalışmalar iki temel bölüme ayrılmıştır.

Tezin ilk bölümünde, gerçek zamanlı rüzgârdan üretilen elektriksel gücün tahmini için, Yapay Sinir Ağları (ANN) ve Destek Vektör Makinaları (SVM) modellerinin kombinasyonuna dayalı çok katmanlı, ileri istatistiksel bir metot geliştirilmiştir. Birinci aşamada, farklı NWP modellerinden gelen rüzgâr hızı ve rüzgâr yönü verileri, çok sayıdaki grid arasından en iyisi seçilerek, geliştirilen rüzgârdan üretilen elektriksel güç tahmin modellerinin eğitim ve testinde kullanılır. İkinci aşamada, her bir NWP verisi için, ANN ve SVM modelleri ayrı ayrı uygulanır. Tahmin hataları model çıktı istatistikleri (MOS) uygulanarak düzeltilir ve 48-saat öncesi rüzgârdan üretilen farklı elektriksel güç tahminleri uygun ağırlıklandırma faktörleri ile kombine edilerek, rüzgârdan üretilen elektriksel gücün 48-saat öncesi ara tahminleri elde edilir. Son aşamada, bu tahmin verileri tekrar kombine edilerek nihai tahminler oluşturulur. Önerilen model, Türkiye'deki 25 Rüzgâr Enerjisi Santralinde (WPP) başarılı bir şekilde test edilmiş ve özellikle dağınık rüzgâr rejimli

karmaşık arazilerdeki WPP'lerde referans modellere oranla çok daha başarılı kısa-dönem rüzgâr gücü üretimi tahmin sonuçları vermiştir.

Tezin ikinci bölümünde ise, kısa-dönem rüzgârdan üretilen elektriksel güç tahminlerini iyileştirmek amacıyla, NWP rüzgâr verisini WPP sahasına indirgemek için RWM ile NWP veri korelasyonu ve rüzgâr örüntü tanıma tekniğine dayalı yeni bir istatistiksel yaklaşım önerilmiştir. Bu amaçla ilk olarak Adaptif Arttırma (AdaBoost) makine öğrenme algoritması kullanılarak her bir WPP çevresindeki NWP verileri grid kümesi arasından uygun meteorolojik grid verisi elde edilir. Daha sonra kombine edilmiş grid verisi sınıflandırılır ve NWP verisi ile RWM ölçümleri arasındaki korelasyon bulunur. Diğer taraftan, rüzgâr örüntüleri arasındaki ilişkiyi öğrenmek üzere her bir sınıf için ANN/SVM modeli oluşturulur. Bu rüzgârdan-rüzgâra aşamasının çıktıları, rüzgârdan-güce aşamasında ardışık istatistiksel ANN/SVM kümeleri uygulanarak, ham, kısa-dönem 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri elde edilir. MOS kullanılarak sistematik hatalar elimine edilir ve ağırlıklandırılmış ortalama kombinasyon metodu ile nihai 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri elde edilir. Önerilen bu model, kurulu güçleri yaklaşık 10 MW ile 200 MW arasında olan yedi WPP'ye uygulanmıştır. Elde edilen rüzgârdan üretilen elektriksel güç tahmin sonuçları, referans modeller ve herhangi bir rüzgâr örüntü tanıma ya da RWM ölçümleri kullanarak NWP veri düzeltmesi kullanmayan diğer istatistiksel modellerle karşılaştırılmıştır. Geliştirilen modelin, iki yıllık ortalama eğitim periyodu ve altı aylık bir test periyodunda, rüzgârdan üretilen elektriksel güç tahminlerinin normalize edilmiş ortalama mutlak hatası üzerinde geleneksel metotlara oranla % 5.1'e kadar bir iyileştirme getirdiği görülmüştür.

Anahtar Kelimeler: Rüzgâr gücü tahmini, ileri istatistiksel metotlar, yapay sinir ağları, destek vektör makinaları, örüntü tanıma, rüzgâr gözlem istasyonu.

ABSTRACT

WIND-ELECTRIC POWER FORECAST USING ADVANCED STATISTICAL METHODS

Serkan BUHAN

**Doctor of Philosophy, Department of
Electrical and Electronics Engineering
Supervisor: Prof. Dr. Işık ÇADIRCI**

December 2015, 100 pages

This thesis aims at forecasting short-term wind-electric power by using multi-stage advanced statistical methods and to improve these forecasts by using Reference Wind Mast (RWM) measurements correlations with Numerical Weather Prediction (NWP) and wind pattern recognition techniques. This thesis work is divided into two parts.

In the first part of the thesis, a multi-stage, advanced statistical method has been proposed for the real-time wind electric power generation forecast, based on a combination of Artificial Neural Network (ANN) and Support Vector Machine (SVM) models. In the first stage, the best grid output data of wind speed and wind direction from different NWP models are chosen among a set of grid points, and used for training and testing the developed wind-electric power forecast models. In the second stage, for each NWP data, ANN and SVM models are applied separately. The forecast errors are corrected by applying Model Output Statistics (MOS) and different 48-hour ahead forecasts of wind-electric power are combined by appropriate weighting factors to obtain an intermediate 48-hour ahead forecast of the electrical power generated from wind. Finally, these forecast data are recombined to give an ultimate forecast. The proposed model is tested on 25 Wind

Power Plants (WPPs) satisfactorily and it performs better than the reference models in terms of short-term wind power generation forecast accuracy, especially for WPPs in complex terrains with a scattered wind regime.

In the second part of the thesis, a new statistical approach has been proposed for improved, short-term wind-electric power forecasts of WPPs based on a new wind pattern recognition technique, and RWM data correlations with NWP to localize wind data to the given WPP site. For this purpose, first, NWP data are combined by Adaptive Boosting (AdaBoost) machine learning algorithm, to provide a proper combination of meteorological grid data from a set of grids around each WPP. Then, combined grid data are clustered and the correlation between NWP data and RWM measurements are found. On the other hand, for each cluster, ANN/SVM model is constructed to learn the relationship between the wind patterns. The outputs of this wind-to-wind stage are used to obtain raw, short-term 48-hour ahead wind-electric power forecasts via the consecutive statistical ANN/SVM sets applied in wind-to-power stage. The systematic errors are eliminated by applying MOS, and a weighted average combination method is used to obtain the final 48-hour ahead wind-electric power forecasts. The proposed model has been successfully applied to seven WPPs, with installed capacities in the range from 10 MW to ~200 MW. The wind-electric power forecast results of the proposed approach have been compared to the reference benchmark models and other statistical models, which do not use any wind pattern recognition, or NWP data correction via RWM measurements. It has been shown that the proposed model, brings an improvement up to 5.1% on the normalized mean absolute error of wind-electric power forecasts, for an average training period of two years and a test period of six months for the given WPPs as compared to conventional methods.

Keywords: Wind power forecast, advanced statistical methods, artificial neural networks, support vector machines, pattern recognition, reference wind mast.

TEŞEKKÜR

Bu tez çalışması boyunca karşılaştığım sorunların çözümünde yardımcı olan ve çalışmanın sağlıklı bir şekilde yürütülmesi için bana yol gösteren değerli tez danışmanım Sayın Prof. Dr. Işık Çadircı'ya,

Tez çalışmalarında sunduğu öneriler ve katkılardan dolayı tez izleme komitesinin değerli üyeleri Prof. Dr. Muammer Ermiş ve Yrd. Doç. Dr. Yakup Özkazanç'a,

Bu tez çalışmasına verdikleri katkı ve desteklerden dolayı TÜBİTAK MAM Enerji Enstitüsü'nde 'Rüzgârdan Üretilen Elektriksel Gücün İzlenmesi ve Tahmini (RİTM)' projesinde birlikte çalıştığım değerli proje arkadaşlarım, Dr. Turan Demirci, Dr. Dilek Küçük, Erman Terciyanlı, Mehmet Barış Özkan, Ali Burhan Haliloğlu, Ceyda Er Köksoy ve Abdullah Bestil'e,

Gösterdiği iyi niyeti ve yardımları için Dr. Tevhid Atalık'a,

Değerli görüş ve önerileri için savunma sınavı jüri üyelerine,

Beni yetiştiren ve bugünlere gelmemde üzerimde büyük emekleri olan sevgili aileme,

Tez çalışmam boyunca tüm kahrımı çeken, hayatıma anlam katan ve her daim destekleyen sevgili eşim Kübra'ya ve biricik kızım Eylül İsra'ya,

içtenlikle teşekkür ederim.

İÇİNDEKİLER

	<u>Sayfa</u>
ÖZET	i
ABSTRACT	iii
TEŞEKKÜR	v
ÇİZELGELER	viii
ŞEKİLLER	ix
SİMGELER VE KISALTMALAR	xi
1. GİRİŞ	1
1.1. Rüzgârdan Üretilen Elektriksel Gücün Tahmini	2
1.2. Tezin Amacı ve Katkısı	7
1.3. Tezin Yapısı	8
2. TEMEL İSTATİSTİKSEL MODELLER İLE RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN TAHMİNİ	10
2.1. Referans Tahmin Modeli	11
2.2. Katman Sayısına Göre Temel İstatistiksel Modeller	11
2.2.1. Tek Katmanlı Modeller	11
2.2.2. Çok Katmanlı Temel Modeller	11
2.3. NWP Kullanımına Göre Temel İstatistiksel Modeller	13
2.3.1. NWP kullanmayan Zaman Serisine Dayalı Yaklaşımlar	13
2.3.2. NWP kullanan Temel İstatistiksel Yaklaşımlar	13
2.4. RWM Tabanlı Temel İstatistiksel Modeller	14
3. RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN ÇOK KATMANLI YAPIYLA TAHMİNİ	16
3.1. Geliştirilen Modelin Tanımı	17
3.2. Geliştirilen Modelin Uygulanması	20
3.2.1. Uygulanan Santraller	21
3.2.2. ANN Model Yapısı ve Parametre Seçimleri	24
3.2.3. SVM Model Yapısı ve Parametre Seçimleri	26
3.2.4. Model İçin Kullanılan Girdiler ve Çıktılar	27
3.2.5. Veri Normalizasyonu ve Tahmin Hata Tanımı	28
3.2.6. Metodun Uygulanması	29
3.3. Geliştirilen Model Sonuçları	31

3.3.1.	Süreklilik Metodu İle Karşılaştırma	34
3.3.2.	Geleneksel Yöntemlerle Karşılaştırma	35
3.3.3.	Veri İşleme	39
4.	İYİLEŞTİRİLMİŞ RÜZGÂR-ELEKTRİK GÜÇ TAHMİNLERİ İÇİN RÜZGÂR ÖRÜNTÜSÜ TANIMA VE RÜZGÂR GÖZLEM İSTASYONU İLE NWP VERİ İLİŞKİSİ.....	41
4.1.	Geliştirilen Model	42
4.1.1.	NWP ve RWM Verisi Arasındaki İlişki	42
4.1.2.	Rüzgâr Örüntüleri	47
4.2.	Geliştirilmiş Rüzgârdan Üretilen Elektriksel Güç Tahmin Modeli	48
4.2.1.	AdaBoost Grid Kombinasyonu ve K-means NWP Veri Sınıflandırması	49
4.2.2.	İstatistiksel Metotlar: ANN ve SVM	49
4.2.3.	MOS ve Kombinasyonlar	51
4.3.	Yöntemin Uygulanması.....	52
4.3.1.	WPP ve RWM Kurulumları	52
4.3.2.	Eğitim Aşaması	54
4.3.3.	Test Aşaması	55
4.4.	Önerilen Modelin Sonuçları	56
4.4.1.	NWP Verisi ile RWM Verisi Karşılaştırması	56
4.4.2.	Geliştirilen Model ile Süreklilik Modeli Karşılaştırması	57
4.4.3.	Önerilen Modelin Diğer İstatistiksel Modellerle Karşılaştırılması	60
5.	SONUÇ	63
	KAYNAKLAR.....	66
	EKLER	73
	ÖZGEÇMİŞ.....	99

ÇİZELGELER

Sayfa

Çizelge 1.1 Rüzgârdan üretilen elektriksel güç için ticari tahmin sistemleri [54]-[75]	6
Çizelge 3.1 Rüzgâr santrallerinin kurulum bilgileri	22
Çizelge 3.2 Tek katmanlı model ile çok katmanlı geliştirilen modelin karşılaştırılması	36
Çizelge 3.3 Geleneksel tahmin yöntemleriyle önerilen modelin karşılaştırılması	38
Çizelge 4.1 WPP'ler ve RWM'lerin bazı teknik özellikleri	53
Çizelge 4.2 RWM ile NWP verileri arasındaki doğrusal ve dairesel korelasyonlar	57
Çizelge 4.3 Temel Test Sonuçları: Sadece NWP verisi ya da sadece RWM ölçümleri ile elde edilen NMAE hata oranları	57
Çizelge 4.4 Rüzgârdan rüzgâra hız ve yön hataları ile NWP hız ve yön hata karşılaştırması	60
Çizelge 4.5 NWP ve RWM veri korelasyonu ile rüzgâr örüntü tanıma yöntemlerinin rüzgârdan üretilen elektriksel güç tahminlerindeki iyileştirmeler	62

ŞEKİLLER

Sayfa

Şekil 2.1 Tek katmanlı temel istatistiksel model.....	12
Şekil 2.2 Çok katmanlı temel istatistiksel tahmin modeli (N: Katman sayısı).....	12
Şekil 2.3 NWP tabanlı temel istatistiksel tahmin modeli blok şeması	14
Şekil 2.4 RWM tabanlı örnek bir tahmin modeli	15
Şekil 3.1 Önerilen tahmin modeli blok diyagramı	17
Şekil 3.2 Örnek bir WPP için en iyi grid seçimi	18
Şekil 3.3 RITM projesindeki 25 santralin konumları,	21
Şekil 3.4 İki farklı santral için rüzgârgülü grafikleri.....	23
Şekil 3.5 ANN tahminleri akış şeması.....	26
Şekil 3.6 SVM tahminleri akış şeması	28
Şekil 3.7 Çapraz-doğrulama yöntemiyle ANN/SVM parametre seçimi	30
Şekil 3.8 Örnek bir WPP için rüzgâr hızı değişimleri	32
Şekil 3.9 Örnek bir WPP için rüzgâr yönü değişimleri	32
Şekil 3.10 Örnek bir WPP için model tahmini ve gerçek güç üretim değişimleri-1	32
Şekil 3.11 25 WPP için toplam tahmin ve gerçek üretim değişimleri-1	33
Şekil 3.12 Örnek bir WPP için model tahmini ve gerçek güç üretim değişimleri-2	33
Şekil 3.13 25 WPP için toplam tahmin ve gerçek üretim değişimleri-2	34
Şekil 3.14 Önerilen metot ile süreklilik metodunun tahmin hatalarının karşılaştırılması, ..	35
Şekil 3.15 Örnek WPP için çok katmanlı ve tek katmanlı yapıların tahmin	37
Şekil 3.16 İlk 14 santral için tek katmanlı, fiziksel, hibrit ve önerilen modelin hata dağılımları.....	39
Şekil 3.17 Geliştirilen model için kullanılan girdiler/çıktılar	40
Şekil 4.1 Örnek bir WPP (WPP1') için rüzgârgülleri	43
Şekil 4.2 Örnek bir WPP için NWP verileri ile RWM ölçüm verileri arasındaki korelasyon	44
Şekil 4.3 Örnek bir WPP (WPP1') için rüzgâr hızına göre rüzgârdan üretilen elektriksel güç değişimleri	46
Şekil 4.4 NWP ve RWM verileri ile elde edilmiş tipik örüntü örneklerinin elips ve dikdörtgen çerçevelerle gösterilmesi	47
Şekil 4.5 Üç NWP rüzgâr hızına karşılık RWM rüzgâr hızı verisi	48
Şekil 4.6 Geliştirilen model için genelleştirilmiş blok şema	49

Şekil 4.7 RWM düzeltme ve rüzgâr örüntü tabanlı önerilen yöntemin eğitim ve test sistemi	50
Şekil 4.8 RWM görünümüleri soldaki: kurulum, sağdaki: yandan görünüş	53
Şekil 4.9 NWP verisi ve RWM verisi örüntüleri kullanılarak $R_s(t)$ rüzgâr hızı tahmini yapılması.....	55
Şekil 4.10 Süreklilik metodu ile önerilen metodun karşılaştırılması	58
Şekil 4.11. Süreklilik metodu ile önerilen metot hata dağılımları.....	59
Şekil 4.12 Düzeltilmiş NWP rüzgâr hızı ile ham NWP ve RWM rüzgâr hızı verileri tipik Weibull dağılımları.....	61
Şekil 0.1 ANN model yapıları (a) Genel ANN modeli (b) Yapay bir nöron modeli	75
Şekil 0.2 Doğrusal SVM Modeli	79
Şekil 0.3 Sayısal Hava Tahmin Modelleri Akış Şeması.....	85
Şekil 0.4 WPP1, WPP2, WPP3, WPP4, WPP5 ve WPP6 santralleri için rüzgârgülleri	88
Şekil 0.5 WPP7, WPP8, WPP9, WPP10, WPP11 ve WPP12 santralleri için rüzgârgülleri.....	89
Şekil 0.6 WPP13, WPP14, WPP15, WPP16, WPP17 ve WPP18 santralleri için rüzgârgülleri.....	90
Şekil 0.7 WPP19, WPP20, WPP21, WPP22, WPP23 ve WPP24 santralleri için rüzgârgülleri.....	91
Şekil 0.8 WPP25 santrali için rüzgârgülü.....	92
Şekil 0.9 NWP ve RWM rüzgârgülleri.....	93
Şekil 0.10 NWP ve RWM rüzgârgülleri.....	94
Şekil 0.11 NWP ve RWM rüzgârgülleri.....	95
Şekil 0.12 WPP1', WPP2' ve WPP3' santralleri için NWP ve RWM rüzgâr-güç eğrileri .	96
Şekil 0.13 WPP4', WPP5' ve WPP6' santralleri için NWP ve RWM rüzgâr-güç eğrileri .	97
Şekil 0.14 WPP7' santrali için NWP ve RWM rüzgâr-güç eğrileri	98

SİMGELER VE KISALTMALAR

Simgeler

Gan	ANN modeli için minimum eğitim hatasını veren gridi
Gsn	SVM modeli için minimum eğitim hatasını veren gridi
T	Tahmin başlangıç günü
λ	Eğitim uzunluğunu gösteren gün sayısı
H	Saat indeksi
t	Gün indeksi
$F_{(a/s)}$	ANN/SVM modelleri için rüzgârdan üretilen elektriksel güç tahmini
$w_{(a/s)}$	ANN/SVM modeli ağırlık değeri
w_{fa}	ANN modeli tahmini için nihai kombinasyon katsayısı
w_{fs}	ANN modeli tahmini için nihai kombinasyon katsayısı
F_f	Son kademedeki nihai rüzgârdan üretilen elektriksel güç tahmini
x_j	Girdi verisi
w_j	Ağırlık katsayıları
N	Eğitim girdi veri sayısı
b_k	k 'inci nöron için bias terimi
v_k	k 'inci nöronun toplam çıktı fonksiyonu
ϕ	Aktivasyon fonksiyonu
γ	Kernel parametresi

Kısaltmalar

ALADIN	Yüksek Çözünürlüklü Hava Tahmin Projesi
ANN	Yapay Sinir Ağları (Artificial Neural Networks)
ARMAX	Dış Kaynak Girdili Oto Regresyon Kayan Ortalama Modeli (Autoregressive Moving Average with Exogenous Input)
ARX	Dış Kaynak Girdili Oto Regresyon Modeli (Autoregressive with Exogenous Input)

DMİ	Devlet Meteoroloji İşleri
ECMWF	Avrupa Orta Ölçekli Hava Tahmin Merkezi (European Center for Medium-Range Weather Forecasts)
FL	Bulanık Mantık (Fuzzy Logic)
GFS	NOAA Tarafından İşletilen Global Sayısal Hava Tahmin Modeli (Global Forecast System)
MAE	Ortalama Mutlak Hata (Mean Absolute Error)
MGM	Meteoroloji Genel Müdürlüğü
MOS	Model Çıktı İstatistiği (Model Output Statistics)
MSE	Hata Karelerinin Ortalaması (Mean Square Error)
NMAE	Normalize Ortalama Mutlak Hata (Normalized Mean Square Error)
NWP	Sayısal Hava Tahminleri (Numerical Weather Prediction)
RWM	Referans Rüzgâr Direği (Reference Wind Mast)
RİTM	Türkiye'de Rüzgârdan Üretilen Elektriksel Güç İçin İzleme ve Tahmin Sistemi Geliştirilmesi Projesi
SVM	Destek Vektör Makineleri (Support Vector Machines)
WEA	Rüzgâr Enerjisi Analizörü (Wind Energy Analyzer)
WPP	Rüzgâr enerjisine dayalı elektrik üretim tesisi (Wind Power Plant)
WRF	Hava Araştırma ve Tahmin Modeli (Weather Research and Forecasting Model)

1. GİRİŞ

Son yıllarda, dünya genelinde toplam enerji üretimindeki rüzgârdan üretilen enerjinin katkısı hızla artmaktadır. Özellikle fosil yakıtlardaki kapasitenin azalması ve bu yakıtların karbon emisyonlarındaki olumsuz etkileri, yenilenebilir enerji kaynaklarının dünya enerji üretiminde yükselen bir değere sahip olmasını sağlamaktadır. Yakın gelecekte dünya enerji talebinin artan trendi devam ederken, küresel ısınma sorununun da hızla önemi artacaktır. Bu kapsamda fosil yakıtların karbon salınımlarının önüne geçmek ya da salınımları kısıtlamak amacıyla yenilenebilir enerji kaynaklarının payının artırılması şimdi olduğu gibi gelecekte de sürekli artan bir öneme sahip olacaktır.

Geleneksel elektrik enerjisi kaynakları ile üretilen elektrik, depolanabilen bir kaynak olmadığından doğrudan iletim ve dağıtım sistemleri ile tüketiciye ulaştırılır. Güç sistemleri yönetimi açısından üretim ile tüketimin, tüm sistem içerisindeki her noktada ve her zamanda dengeli tutulması esastır. Bu nedenle elektrik enerjisi talebine göre uygun miktarda üretimin planlanması, sağlanması ve tüketicinin kullanımına sunulması çok önemlidir.

Geleneksel elektrik enerjisi kaynaklarından farklı olarak rüzgâr enerjisi, üretimi planlanabilen bir kaynak değildir. Rüzgârın olduğu anda yüksek miktarlarda üretim yapılabilirken, rüzgârın olmadığı zamanlarda hiç üretimin olmaması, rüzgârın elektrik sistemine entegrasyon ve üretim-tüketim dengesi açısından planlaması ne denli zor bir enerji kaynağı olduğunu göstermektedir.

Tüm bu talep artışları ve planlama zorlukları sonucunda rüzgârdan üretilen elektriksel güç üretim tahmini çalışmaları, elektrik marketi için kritik önem kazanmıştır. Elektrik sistemindeki rüzgâr enerjisi ile üretilen elektriğin büyük ölçekteki artan katkısı, rüzgârın stokastik doğasından kaynaklanan belirsiz ve kesintili yapısı nedeniyle güvenilir, gerçek zamanlı rüzgâr üretim tahminlerinin yapılabilmesine ihtiyaç duyulmuştur [1]-[3].

Rüzgârdan üretilen elektriksel gücün üretim tahminleri, tek başına elektrik sisteminde rüzgâr enerjisinin entegrasyon zorluklarının çözümü olmaktan çok, sistem yöneticileri tarafından kullanılarak, maliyet politikalarında ve rüzgâr enerjisinin elektrik sistemine optimum entegrasyonunda kilit rol oynarlar [4]. Hem sistem operatörü açısından hem de rüzgâr enerjisi santrali (WPP) sahipleri açısından kısa dönem rüzgâr üretim tahminleri oldukça önemlidir. Sistem operatörü, gün öncesi planlamaları için bu tahminlere ihtiyaç

duyarken, WPP sahipleri de rüzgârdan üretilen elektriksel güç için oluşturulmuş marketteki pozisyonlarını belirlemede bu tahminlere ihtiyaç duyar.

1.1. Rüzgârdan Üretilen Elektriksel Gücün Tahmini

Rüzgârdan üretilen elektriksel gücün tahmin edilmesi, rüzgârın stokastik doğasından kaynaklanan nedenlerden dolayı diğer kararlı elektrik enerjisi kaynaklarına oranla çok daha zordur. Elektrik piyasasındaki tüm oyuncular için bu tahminler kritik öneme sahiptir. Son yıllarda literatürde, özellikle 6-72 saat aralığındaki kısa dönemli rüzgârdan üretilen elektriksel gücün tahminine yönelik çalışmalar önem kazanmıştır. Bu yöntemler arasında ileri istatistiksel yöntemler, kolay uygulanabilirliği, fiziksel herhangi bir veriye ihtiyaç duymaması ve başarılı tahmin sonuçları sayesinde ön plana çıkmış yöntemlerdir.

Literatürde, rüzgârdan üretilen elektriksel gücün tahminleri araştırmalarında son yıllarda dikkate değer bir artış olduğu gözlemlenmektedir [5], [6], [7]. Yapılan bu çalışmalar temel olarak üç farklı kategoriye ayrılmıştır [8]. Bunlar sırasıyla, fiziksel model, istatistiksel model ve hibrit modeldir. Fiziksel model, uygulanan WPP sahasının arazi, bitki örtüsü gibi fiziksel özelliklerini dikkate alarak genellikle sayısal hava tahminleri (NWP) verisini de kullanan bir tahmin modelidir. İstatistiksel model ise, geçmiş meteorolojik rüzgâr verisini ve rüzgârdan üretilen güç verisini esas alan bir model yapısıdır. Hibrit tahmin modeli ise hem fiziksel hem de istatistiksel modelleri birlikte kullanarak oluşturulan tahmin modelidir [9], [10].

Fiziksel modeller temel olarak sayısal bir meteorolojik grid üzerine inşa edilmiş NWP verisinin WPP saha koşullarına dönüşümü ile ilgilenir [11]. Bu dönüşüm sırasında WPP'lerin orografi ve pürüzlülük gibi arazi karakteristikleri dikkate alınarak, güce çevirme aşamasında girdi olarak kullanılmak üzere, orta ölçekli NWP model tahminlerinin sadeleştirmeleri yapılır. Rüzgârdan-güce dönüşüm aşamasında rüzgâr-güç eğrilerinden yararlanılır. Bu eğriler üretici tarafından oluşturulan eğriler de olabildiği gibi ölçülen veya tahmin edilen rüzgâr hızı ve yönü verileri ile güç üretim verilerinin kullanılması ile de elde edilmiş olabilir [12]. Genellikle, sistematik hataların giderilmesinde nihai fiziksel tahminler oluşturulmadan hemen önce Model Çıktı İstatistiği (MOS) yöntemi uygulanarak son tahminlere ulaşılır [13].

İstatistiksel modeller, rüzgârdan üretilen elektriksel gücün tahminini yapabilmek için NWP verisi ile geçmiş rüzgâr ölçüm verileri ve rüzgârdan üretilen elektriksel güç üretim verileri arasındaki ilişkiyi ortaya çıkaran istatistiksel yaklaşımlardan oluşur. Model parametrelerini

elde ederken herhangi bir fiziksel bilgi kullanmaz. Sadece istatistiksel model kullanan yöntemlerin özellikle kısa dönem rüzgârdan üretilen elektriksel güç tahminlerinde başarılı sonuçlar verdiği görülmektedir [14], [15], [16].

Kısa dönem rüzgârdan üretilen elektriksel güç tahminleri, özellikle 6-48 aralığındaki tahminler, uygulama kolaylığı ve daha iyi doğrulukta sonuçları nedeniyle hem doğrusal hem de doğrusal olmayan yöntemleri kullanmaktadır [17]. Doğrusal modeller genellikle regresyon türünde modelleri kapsar. Bu modeller Oto Regresyon (AR), Dış Girdili Oto Regresyon (ARX), Kayan Ortalama (MA), Oto Regresyon Kayan Ortalama (ARMA), Dış Girdili Oto Regresyon Kayan Ortalama (ARMAX), Oto Regresyon Entegre Kayan Ortalama (ARIMA), Kalman Filtre v.b. modellerden oluşur [8], [18]-[20]. İstatistiksel yaklaşımlardaki doğrusal modeller sıklıkla zaman serisi modellerini esas alır. Ölçülen ve zaman-kaymalı rüzgârdan üretilen elektriksel güç verisi ile dış girdileri de kullanarak yinelemeli olarak zaman serileri üzerinden rüzgârdan üretilen elektriksel güç üretim tahminleri yapılır.

Doğrusal olmayan modeller, Yapay Sinir Ağları (ANN), Destek Vektör Makinaları (SVM), Bulanık Mantık (FL) v.b. yöntemler ile bu yöntemleri hibrit olarak bir arada bulunduran yapıları kullanır [21], [22]-[26]. Yapılan çalışmalar neticesinde kullanılan veri kümesini dikkate alan iyi bir parametre optimizasyonu yapılan doğrusal olmayan modellerin rüzgârdan üretilen elektriksel gücün tahmininde doğrusal modellere oranla daha başarılı sonuçlar verdiği görülmektedir [8], [27]. Doğrusal modellerden farklı olarak, doğrusal olmayan modeller, NWP ile rüzgârdan üretilen elektriksel güç arasındaki ilişkiyi makine öğrenme algoritmaları sayesinde öğrenir. Özellikle rüzgâr ve güç tahmini gibi doğrusal olmayan ilişkileri belirlemede gösterdikleri başarı nedeniyle ANN ve SVM modelleri daha fazla ilgi çekmektedir.

Çalışma [28] ve [29]'da, SVM tabanlı bir model rüzgâr hızı tahmini için kullanılırken, çalışma [30]'da ise rüzgârdan üretilen elektriksel güç tahmini için Dalgacık Dönüşümü (WT)-SVM tabanlı bir model kullanılmıştır. Benzer şekilde, ANN tabanlı modeller hem rüzgârdan üretilen elektriksel gücün tahmininde hem de rüzgâr hızı tahmininde güçlü modellerdir [31]. Bu modeller, Tekrarlayan ANN [32], Ridgelet ANN [33] ve Elman ANN [34] modelleri gibi birçok farklı modeli içermektedir.

Rüzgâr üretim tahminlerinde, literatürde en temel tahmin ve kıyaslama modeli olarak sıklıkla kullanılan model Süreklilik modelidir (Persistans modeli) [35]. Bu model, geçmiş

veriyi (güç veya hız) kullanarak gelecek tahmini yapar. Gelecekteki bu tahminin geçmişteki değer ile aynı olacağı ve değişmeyeceği temeline dayanır. Özellikle 0-6 saat aralığındaki çok kısa-dönem rüzgâr tahminlerinde oldukça iyi sonuçlar verir. Kısa-dönem rüzgâr tahminlerinde ise nispeten tahmin performansı azalsa da, literatürde önerilen tüm yeni tahmin modelleri, performans kıyaslama modeli olarak gördükleri Süreklilik modelinden daha iyi tahmin sonucu ortaya koymaya çalışmaktadırlar [21].

Son yıllarda, rüzgârdan üretilen elektriksel gücün tahmin doğruluğunu arttırmak için yeni çalışmalar yapılmıştır [36]. Özellikle NWP verileri ile oluşturulan modeller, NWP verilerinin kullanılmadığı modellere oranla daha yüksek tahmin doğruluklarına ulaşmaktadır [37], [38], [32], [39]-[42]. Ancak yapılan çalışmaların ortaya koyduğu bir başka sonuç ise, NWP kullanılarak yapılan tahminlerin sonuçları başarılı olsa da, var olan tahmin hatalarının büyük kısmının rüzgâr parametrelerinin tahmininden, yani NWP'den geldiği gerçeğidir [43]-[45].

Çalışma [46]'da, geçmiş güç ölçümleri ile meteorolojik rüzgâr hız ve yön tahminleri girdi olarak kullanılmış ve yapay zekâ tabanlı rüzgârdan üretilen elektriksel güç tahminleri uygulanmıştır. Birden fazla gözlem noktasından elde edilen verilerle oluşturulan yöntemin tahmin doğruluğunu arttırdığı görülmüştür [47]. Bu çalışmada kullanılan model iki aşamadan oluşmaktadır. Birinci aşamada, yapay zekâ ve bulanık mantık yöntemleri ile rüzgâr hızı tahminleri yapılmış, ikinci aşamada ise, WPP güç eğrisi kullanılarak rüzgâr-güç dönüşümü yapılmıştır.

Çok katmanlı, ileri istatistiksel yöntemler, yakın dönem çalışmalarında ilgi çeken yöntemler olmuştur. NWP tabanlı, iki kademeli tahmin modeli çalışma [48]'de anlatılmıştır. Bu model, Bayes sınıflandırıcı (BCD) ve Destek Vektör Regresyonu (SVR) kullanarak 48-saat öncesi rüzgârdan üretilen elektriksel güç üretim tahminleri için iki aşamalı bir ağ modeli oluşturmaktadır. Model, Amerika Birleşik Devletleri'nde (ABD) 74 MW kurulu güce sahip bir rüzgâr enerjisi santralinde test edilmiştir. Çalışma [49]'da diğer bir iki aşamalı yöntem anlatılmıştır. Bu yöntemde ise Uyarlamalı Dalgacık Sinir Ağları (AWNN) ile oluşturulmuş yapı ile ilk aşamada 30-saat öncesi rüzgâr hız tahminleri yapılmış, İleri Beslemeli Sinir Ağları (FFNN) ile ikinci aşamada rüzgâr hızından güce geçiş sağlanmıştır. Ayrıca çok katmanlı çalışmalarda, grup tahminleri yöntemi sayesinde birden fazla NWP girdisinin kombine edilerek tahminlerin iyileştirilmesi sağlanmaktadır. Sonuç olarak, grup yaklaşımı ile yapılan rüzgârdan üretilen elektriksel güç tahminleri tek NWP girdisi kullanan modellere oranla daha iyi sonuçlar vermektedir [50].

Literatürde yakın dönemde önemi artan bir diğer temel yaklaşım ise, NWP verilerinin getirdiği hataların minimize edilebilmesi için rüzgâr gözlem istasyonu (RWM) ölçümleri sayesinde NWP verilerinin santral sahasına indirgenmesi olmuştur. Bu noktada NWP ile RWM verisi arasındaki ilişkiyi belirlemek hayati bir öneme sahiptir [48], [50].

Rüzgârdan üretilen elektriksel güç tahmin sonuçlarının NWP verisi ile RWM verisi arasındaki ilişkiyi belirleyerek iyileştirilmesi için özel yöntemler kullanılmalıdır. Bu yöntemlerden örüntü tanıma temelinde yapılan çalışmalar yetersiz kalmakla beraber yakın zamanda bazı çalışmalara konu olmaya başlamıştır [52], [53].

Çalışma [52]'de, uzun dönem rüzgâr hızı tahmini için genel örüntü tanıma temelinde bir metod kullanılmıştır. İstatistiksel ANN yöntemi kullanan bu çalışmada, bir sonraki yılın saatlik bazda rüzgâr hızı tahmini yapılmıştır. Malezya'da iki farklı meteoroloji istasyonundan alınan rüzgâr hızı ölçümleri kullanılmış ancak NWP verisi kullanılmamıştır.

Çalışma [53]'te, yine rüzgâr hızı tahmini yapmak üzere örüntü tanıma bazlı bir geliştirilmiş temel bileşen analiz metodu önerilmiştir. Her bir bireysel örüntü için ayrı bir tahmin fonksiyonu eğitilmiş ve nihai tahminler ise bireysel tahminlerin kombine edilmesi ile oluşturulmuştur. Kullanılan model veri tabanlı modelleme yapan ancak NWP verisi kullanmayan bir yapı olarak önerilmiştir. Çalışma sonuçlarında önerilen modelin, sınıflandırma, SVM regresyon ve Süreklilik referans modeli tabanlı yaklaşımlarından daha iyi sonuçlar verdiği belirtilmiştir.

Tüm bu çalışmalar ışığında hem Dünya'da gerçekleştirilen büyük çaptaki fiziksel, istatistiksel ve hibrit tabanlı, rüzgârdan üretilen elektriksel gücün tahmini sistemleri, özetlenmiş olarak teknik özellikleri ve doğrulukları ile birlikte Çizelge 1.1'de verilmiştir.

Çizelge 1.1 Rüzgârdan üretilen elektriksel güç için ticari tahmin sistemleri [54]-[75]
(MAE: Ortalama Mutlak Hata, NMAE: Normalize Ortalama Mutlak Hata,
NRMSE: Normalize Kök Ortalama Kare Hata)

FİZİKSEL MODELLER	Geliştiren, Ülke	Raporlanan Hata / İyileştirme	Önemli Özellikler
Prediktor	Risø, Danimarka [54]	1-gün öncesi % 14.2-22.5 MAE	NWP verisi kullanılır. Rüzgâr-Güç eğrisi ve RWM kullanılır. Santral sahasına rüzgâr verisinin taşınması sağlanır.
Casandra¹, MeteoLógica²	Castilla-La Üniversitesi Mancha / Gamesa ¹ [55], MeteoLógica ² [56], İspanya	1-saat öncesi: < %10 NMAE ¹	
SOWIE	Eurowind GmbH, Almanya [57]	-	
Precise Stream	Precision Wind, ABD [58]	1-gün öncesi: % 10-17 NMAE	
İSTATİSTİKSEL MODELLER	Geliştiren, Ülke	Raporlanan Hata / İyileştirme	Önemli Özellikler
WPPT	IMM.DTU/ENFOR, Danimarka [59]	36-saat öncesi: % 9-27 NRMSE	Birden fazla NWP verisi, gerçek zamanlı ölçümler, RWM ve istatistiksel modeller kullanılır. Tahmin kombinasyonları uygulanır. Nokta ve belirsizlik tahminleri yapılır.
AWPPS	ARMINES, Fransa [60]	1- gün öncesi: % 51 iyileşme	
WPMS	ISET, Almanya [61]	1- gün öncesi: % 5-7 NRMSE	
Sipreólico³, AleaWind⁴	3 Carlos Üniversitesi Madrid ³ [62], AleaSoft ⁴ [63], İspanya	24-48-saat öncesi: <% 30 NMAE ¹	
GH Forecaster	Garrard Hassan, İngiltere [64]	12-saat öncesi: % 46-63 iyileşme	
EPREV	INESC Porto, Portekiz [65]	72-saat öncesi: % 66 İyileşme	
Visionpoint⁵, PowerSight⁶	WindLogics ⁵ [66], 3TIER ⁶ [67], ABD	1-gün öncesi: % 12-20 NMAE 1-gün öncesi: % 11-14 NMAE	
HİBRİT MODELLER	Geliştiren, Ülke	Raporlanan Hata / İyileştirme	Önemli Özellikler
Previento⁷, WEPROG⁸	Oldenburg Üniversitesi ⁷ [68], WEPROG ⁸ [69], Almanya	2- gün öncesi: % 6.5 NRMSE ¹ 1- gün öncesi: % 6 NMAE ²	SCADA verisi, NWP verisi ve rüzgâr direk verisi kullanılır. Fiziksel ve istatistiksel yöntemler kombine edilir. Bölgesel ve kararsızlık tahminleri yapılır.
LocalPred	CENER, İspanya [70]	1- gün öncesi: % 12-15 NMAE	
Zephyr	Risø and IMM.DTU, Danimarka [71]	-	
Scirocco	Aeolis, Hollanda [72]	-	
eWind⁹, WEFS¹⁰	AWS ⁹ [73], AMI ¹⁰ [74], ABD	2- gün öncesi: % 28.3 İyileşme ¹⁰	
RITM	TÜBİTAK, Türkiye [75].	1- gün öncesi: % 8-16 NMAE	

1.2. Tezin Amacı ve Katkısı

Bu tez çalışmasının amacı, istatistiksel yöntemlerle çok katmanlı yapıları bir arada kullanarak başarılı bir şekilde 48-saat öncesinden saatlik çözünürlükte rüzgârdan üretilen elektriksel gücün üretim tahminlerini yapabilmektir. Ayrıca, elde edilen bu tahminlerin, rüzgâr gözlem istasyonları verileri ile sayısal hava tahmin modelleri arasında korelasyon kurarak ve rüzgâr örüntü tanıma teknikleri kullanarak önerilen yeni yöntemlerle iyileştirilmesi de amaçlanmaktadır.

Türkiye Bilimsel ve Teknolojik Araştırmalar Kurumu (TÜBİTAK) tarafından yürütülen “Türkiye’de Rüzgârdan Üretilen Elektriksel Gücün Tahmini ve İzlenmesi (RİTM)” projesi kapsamında başlanan çalışmalarda, istatistiksel modellerle gerçek zamanlı kısa-dönem (48 saat öncesi) rüzgârdan üretilen elektriksel gücün üretim tahminlerini gerçekleştirmek amaçlanmıştır [75]. Bu amaçla tezin ilk bölümünde çok katmanlı, aşamalı ileri istatistiksel modellerden oluşan bir yapı geliştirilmiş olup Türkiye genelinde RİTM projesine dâhil olmuş 25 WPP için 48-saat öncesine kadar gerçek zamanlı tahminler çıkarılabilmektedir. İstatistiksel yapıların avantajları düşünülerek geliştirilen tahmin modelleri bu temele dayandırılmıştır.

Tezin ikinci bölümünde ise amaç, daha önce elde edilmiş tahmin modelinden farklı olarak yeni bir yaklaşım sergileyerek, rüzgârdan üretilen elektriksel güç üretim tahminlerini iyileştirmektir. Bu kapsamda RİTM projesindeki 25 WPP arasından RWM kurulmuş olan 7 WPP seçilmiştir. Geliştirilen bu ikinci modelde, RWM verileri kullanarak NWP modellerinden gelen, içerisinde santral sahasını yeterince barındırmayan rüzgâr tahminlerinin, santral sahasına aktararak iyileştirilmiş tahminler elde etmek amaçlanmıştır. Ayrıca santral sahasına indirgenen bu rüzgâr tahmin verileriyle, NWP ile RWM rüzgâr örüntüleri arasındaki ilişkiyi belirleyerek daha başarılı tahminler elde etmek hedeflenmiştir.

Bu tez çalışmasında geliştirilen modellerin literatüre yaptığı özgün katkılar şu şekilde ifade edilebilir:

- Her bir WPP için en yakın dokuz NWP grid verisi arasından en iyi gridi seçen yeni bir yaklaşım önerilmiştir. Bu yöntemde tüm ANN ve SVM modelleri en yakın dokuz grid verisi ile eğitilir ve bu eğitim sonucunda en az hatayı veren grid en iyi grid olarak seçilir. Her bir NWP grid verisi için bu yöntem uygulanarak n sayıda NWP gridi için n sayıda en iyi grid seçimi yapılır.

- En iyi grid seçiminden sonra, farklı orta ölçekli modellerden elde edilmiş çoklu NWP girdisi için WPP bazlı ANN ve SVM modelleri oluşturulur. Özellikle, karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde bu şekilde tahmin sonuçlarının daha iyi olduğu görülmüştür. Çoklu NWP girdi yapısı kullanmak, tek NWP modeli kullanarak oluşturulmuş modellerden gelen bireysel sistematik hataların giderilmesini sağlamaktadır. Bütün NWP girdileri ile seçilmiş olan en iyi grid verisi kullanılarak ANN ve SVM modelleri ile oluşturulan ara tahminler ardışık iki kademe ile birleştirilerek nihai tahmin elde edilir. Her bir bireysel ara tahminden gelen sistematik hatalar, ağırlıklandırılmış ortalama kombinasyon yöntemiyle elenerek en az hatayı veren rüzgârdan üretilen elektriksel güç tahmini elde edilir.
- Rüzgârdan üretilen elektriksel güç tahminlerinde dikkate değer bir iyileşme sağlamak için yeni bir örüntü tanıma tekniği temelinde istatistiksel tahmin modeli geliştirilmiştir. Model, rüzgârın zamanda periyodikliğini kullanarak geçmiş 24 ve 48 saat rüzgâr verisini dikkate alır. Bu bilgiyi dikkate alarak NWP ve RWM rüzgâr verisi örüntülerinin arasındaki benzerlikleri belirler. Böylece NWP verisinden gelen hatalar RWM ölçümleri sayesinde minimize edilmiş olur.
- Yeni bir rüzgârdan rüzgâra düzeltme tekniği ile her bir WPP için, NWP verileri RWM ölçüm verilerine yaklaştırılarak santral sahasına indirgenir. NWP ile RWM verileri arasındaki ilişkiye dayalı bu düzeltme sayesinde daha iyi sonuç veren rüzgârdan üretilen elektriksel güç tahminleri daha da iyileştirilebilmektedir.
- Geliştirilen bu yeni tahmin yapısı içerisinde sırasıyla, uyarlamalı yükseltme temelinde grid kombinasyonu, NWP veri sınıflandırması, RWM ölçümleri ile NWP veri düzeltme, rüzgâr örüntüsü tanıma bazlı öğrenme, ANN/SVM modelleri kullanarak rüzgârdan-rüzgâra geçiş ve rüzgârdan-güce geçiş, sistematik hata giderimi için MOS ve nihai bir tahmin üretmek için ağırlıklandırılmış ortalama kombinasyonu yaklaşımı uygulanmaktadır.

1.3. Tezin Yapısı

Bu tez çalışmasında, rüzgârdan üretilen elektriksel gücün tahmini için ileri istatistiksel metotlar kullanılarak çok katmanlı yaklaşımlar geliştirilmiştir. Geliştirilen iki ayrı tahmin modeli ile 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri yapılmıştır. Tez beş ana bölüm ve eklerden oluşmaktadır.

Birinci bölümde, rüzgârdan üretilen elektriksel güç tahminleri ile ilgili genel bilgiler verilmiş, tezin amacı ve genel yapısı anlatılmıştır. Ayrıca literatürde yapılmış rüzgârdan üretilen elektriksel güç tahminleri ile ilgili çalışmalar derlenerek, hem bireysel teorik çalışmalar hem de ülkeler bazında operasyonel tahmin modelleri anlatılmıştır.

İkinci bölümde, temel istatistiksel modeller ile rüzgârdan üretilen elektriksel gücün tahmini modelleri anlatılmıştır. Özellikle en temel tahmin modellerinden başlanarak ileri istatistiksel modellere geçiş, aşamalı olarak detaylıca anlatılmıştır.

Üçüncü bölümde, geliştirilen ilk model olan, ileri istatistiksel metotlar kullanılarak çok katmanlı rüzgârdan üretilen elektriksel güç tahmin modeli anlatılmıştır. Geliştirilen model 25 WPP için uygulanmış ve elde edilen sonuçlar verilmiştir.

Dördüncü bölümde ise, RWM verileri kullanılarak korelasyon ve örüntü tanıma temelinde geliştirilen ikinci bir model anlatılmıştır. Bu modelin ilk kısmında NWP ile RWM korelasyonunun nasıl bulunduğu anlatılırken ikinci kısmında NWP ile RWM örüntüleri arasında periyodik benzerlik bulunarak bunun tahminlerin iyileştirilmesine katkısı anlatılmıştır.

Ekler bölümünde, sırasıyla, Türkçe-İngilizce terimler sözlüğü, temel istatistiksel model yaklaşımları, orta ölçekli hava tahmin modelleri anlatılmıştır. Daha sonra santrallerin rüzgârgülleri, NWP ve RWM rüzgârgülü karşılaştırması ve rüzgar-güç eğrileri verilmiştir.

2. TEMEL İSTATİSTİKSEL MODELLER İLE RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN TAHMİNİ

Rüzgârdan üretilen elektriksel gücün tahmini yöntemleri üç ana kategoriye ayrılmaktadır. Bunlar sırasıyla fiziksel, istatistiksel ve hibrit modellerdir. Tüm bu modeller çok kısa-dönem (0-6 saat), kısa-dönem (6-72 saat) ve uzun-dönem (72 saat üzeri) tahminlerde kullanılan modellerdir. Fiziksel tahmin en çok uzun-dönem tahminlerde başarılı olurken, istatistiksel ve hibrit modeller ise özellikle çok kısa-dönem ve kısa-dönem tahminlerde daha başarılı sonuçlar vermektedir. Fiziksel tahminler için santralin fiziksel özellikleri (oroğrafi, pürüzlülük v.b.) tahmin yapısı için kullanılır. Ayrıca MOS yöntemleri NWP verilerinin santral sahasına indirgenerek sistematik hataların giderilmesinde kullanılır. İstatistiksel tahmin yöntemlerinde ise geçmiş NWP verilerinin ve güç üretim verilerinin olması başarılı tahminler elde etmek için yeterlidir. Fiziksel herhangi bir veri bu yaklaşımların tahmin oluşturması için gerekli değildir. Hibrit modeller ise, fiziksel ve istatistiksel modellerin birleştirilmesinden oluştukları için, hem santral sahasına ait fiziksel bilgilere ihtiyaç duyarlar hem de geçmiş rüzgâr ve güç verilerine ihtiyaç duyarlar. Tüm bu değerlendirmeler neticesinde özellikle fiziksel veriye ihtiyaç duymadan başarılı tahmin sonuçları verebilen istatistiksel yöntemler bu tez çalışmasının esas modellerini oluşturmaktadır.

Bu tez çalışmasında geliştirilen yaklaşımlar ileri istatistiksel modellerden oluşan rüzgârdan üretilen elektriksel gücün tahmini temeline dayanmaktadır. İleri istatistiksel yöntemler temel istatistiksel yöntemlerin yetersiz olduğu noktaları belirleyerek, farklı kombinasyonlar ve tahmin yapıları kullanarak daha başarılı tahmin sonuçları elde etmek amacıyla yapılmıştır.

Temel tahmin modellerinden ileri tahmin modellerine ulaşırken, farklı girdiler kullanan, model yapıları farklı oluşturulmuş birçok yaklaşım sergilenmektedir. Öncelikle ileri istatistiksel modellerin performanslarını belirlemede de kullanılan en temel tahmin modeli referans tahmin modelidir (süreklilik modeli). Referans model ile başlayan tahmin yaklaşımları geliştirilerek ileri seviyedeki tahmin modellerine ulaşılmıştır. Tüm bu yaklaşımlar değerlendirilirken, modeller belli başlı sınıflandırmalarla birbirinden ayrıştırılırlar. Bu sınıflandırma kriterleri esas olarak, NWP veri ya da verilerinin kullanılıp kullanılmadığına, RWM verilerinin kullanılıp kullanılmadığına, modelin rüzgârdan güce kaç basamakta geçtiğine dair değerlendirmeler yapılarak oluşturulur.

2.1. Referans Tahmin Modeli

Rüzgâr tahminlerinde kullanılan referans model süreklilik modelidir. Bu model, tahmin anında rüzgâr ya da rüzgârdan üretilen elektriksel gücün değeri ne ise gelecekte de aynı değerin olacağı temeline dayanmaktadır. Bu yaklaşım Eşitlik (2.1)'de verilmiştir.

$$f(t + k) = f(t) \quad (2.1)$$

Burada, f süreklilik tahmin fonksiyonunu, t ve k ise tahmin zamanlarını ifade etmektedir.

Operasyonel olarak süreklilik modeli kullanan temel bir tahmin modeli, en güncel rüzgâr hızı ya da gücü değerlerini girdi olarak kullanmak zorundadır. Oldukça basit bir tahmin modeli olmasına rağmen, özellikle ileri istatistiksel modellerin performans kriteri olarak kullanılmaktadır. Kısa dönem tahminlerde süreklilik modelinden çok daha başarılı tahmin sonuçları vermesi beklenen başarılı ileri istatistiksel modeller, çok kısa dönem (1-6 saat) tahminlerinde rüzgârın doğasından dolayı süreklilik modelinden daha başarılı sonuçlar elde etmekte oldukça zorlanırlar. Bu nedenle özellikle çok kısa süreli rüzgârdan üretilen elektriksel gücün tahmini çalışmalarında süreklilik modelinin de dâhil olduğu yaklaşımlar kullanılmaktadır.

2.2. Katman Sayısına Göre Temel İstatistiksel Modeller

Temel modeller kullanılan basamak sayısı, NWP verisinin girdi olarak kullanılıp kullanılmadığı, RWM verisi kullanılıp kullanılmadığı gibi kategorilere ayrılabilir.

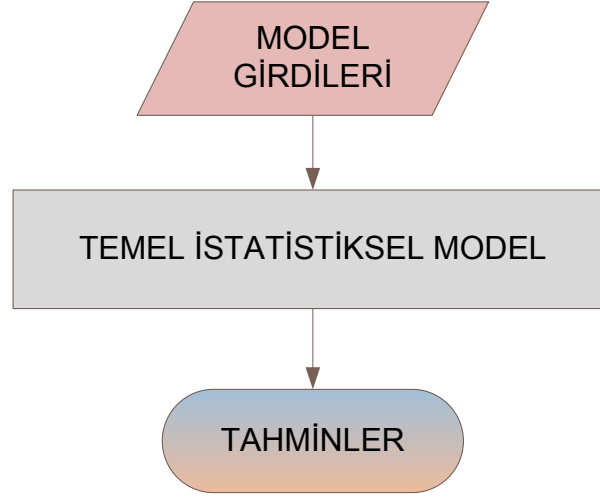
2.2.1. Tek Katmanlı Modeller

Tek katmanlı temel istatistiksel modeller, girdi olarak kullanılan veriyi herhangi bir ileri basamak kullanmadan güç tahminlerine dönüştüren modellerdir. Bu modellerin veri akış mekanizmasını ifade eden şema Şekil 2.1'de verilmiştir. Model girdileri arasında sadece rüzgâr güç zaman serisi olabileceği gibi, tek ya da çoklu NWP verisi de olabilir.

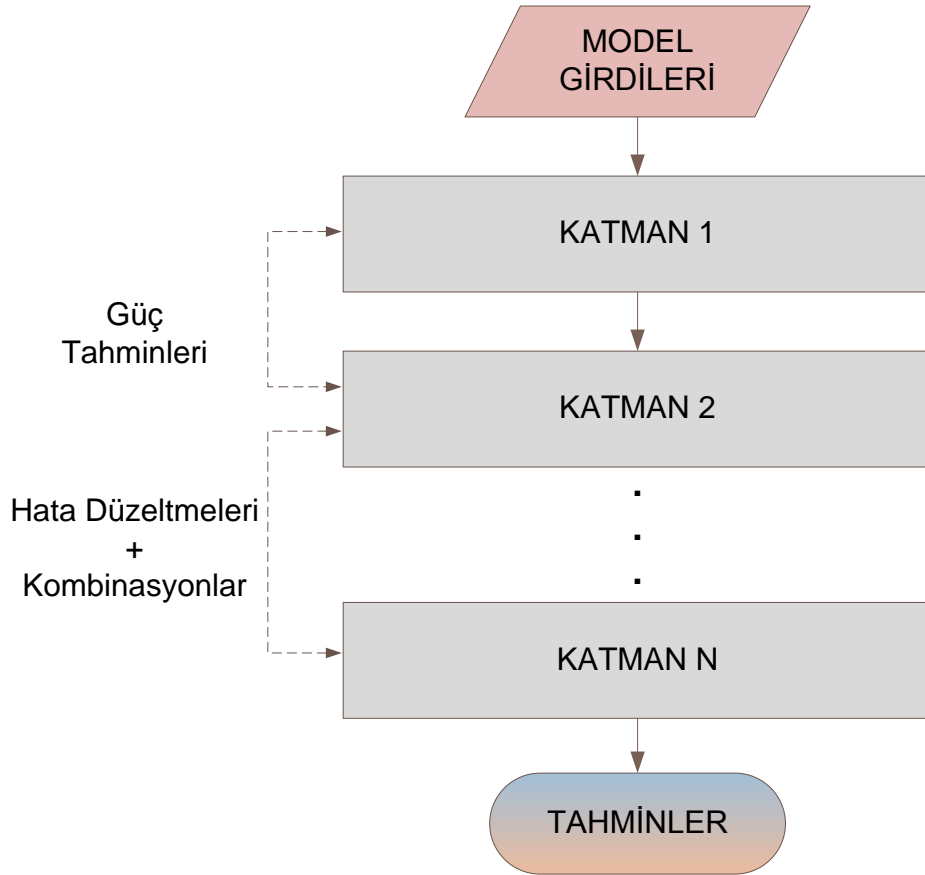
2.2.2. Çok Katmanlı Temel Modeller

Temel modellerden birden fazla katmanlı yapılar kullanarak rüzgârdan üretilen elektriksel güç tahminleri yapılmaktadır. Bu yaklaşımlarda ilk katmanda model girdileri kullanılarak güce dönüştürülür ve ikinci ve sonraki katmanlarda ise sistematik hata düzeltmeleri ve kombinasyonlar gibi yaklaşımlarla hatalar mümkün olduğunca minimize edilmeye çalışılır. Bu temel yöntemlerden çok katmanlı yapıyı gösteren şema Şekil 2.2'de verilmiştir. Model girdileri tek katmanlı modelde olduğu gibi, NWP verisi olmayan, tek NWP verisi olan ve çoklu NWP verisi olan modellerden oluşmaktadır. Güce dönüşümde çoğunlukla doğrusal

olmayan yöntemler kullanılır. Daha sonra elde edilen ham güç tahminleri hata düzeltmeleri ve birden fazla NWP girdili yapılar için kombinasyon yöntemleri kullanılarak nihai istatistiksel güç tahminleri elde edilir.



Şekil 2.1 Tek katmanlı temel istatistiksel model



Şekil 2.2 Çok katmanlı temel istatistiksel tahmin modeli (N: Katman sayısı)

2.3. NWP Kullanımına Göre Temel İstatistiksel Modeller

Katman sayısından bağımsız olarak temel istatistiksel modeller, yapılarında girdi olarak NWP verisi kullanılıp kullanılmadığına göre sınıflandırılabilirler. NWP verisini kullanmayan ve sadece rüzgâr ya da güç zaman serisini kullanan yapılar ile NWP rüzgâr verilerini kullanarak rüzgâr üretim tahminleri yapan yapılar olmak üzere iki temel tahmin yapısı bulunmaktadır.

2.3.1. NWP Kullanmayan Zaman Serisine Dayalı Yaklaşımlar

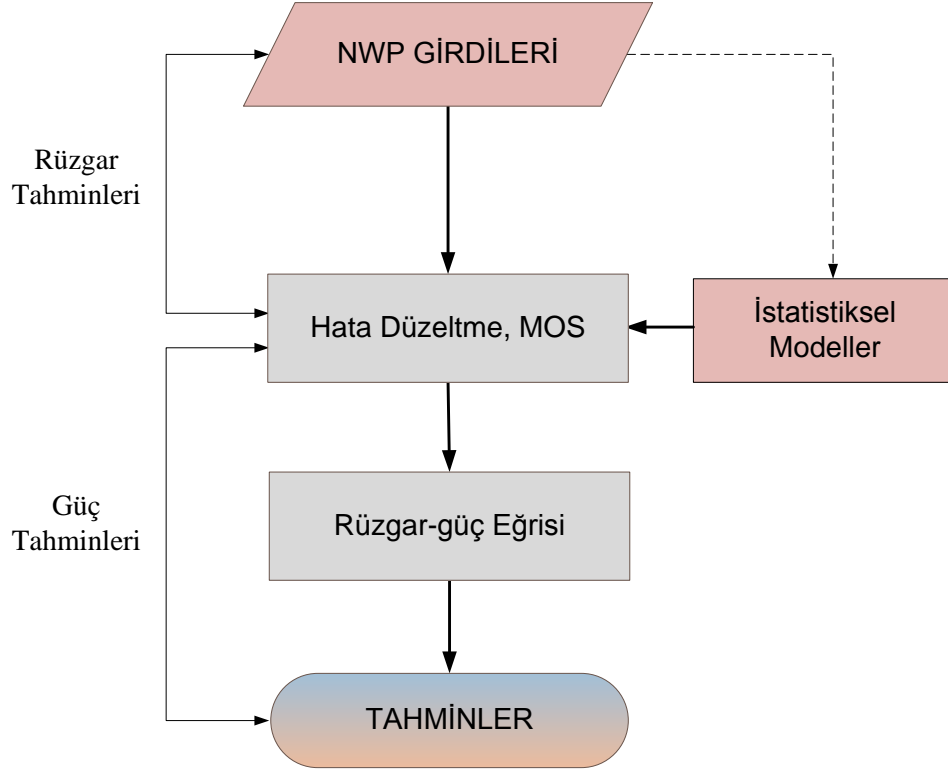
Regresyon temelindeki modeller kullanarak öncelikle rüzgâr hızı ve yönü zaman serileri kullanarak, gelecek rüzgâr hızı ve yönü tahminleri yapılır. Daha sonra elde edilen tahmin ile rüzgâr verileri ve santral rüzgâr güç eğrisi kullanılarak rüzgâr üretim tahminleri yapılır. Rüzgâr zaman verilerini kullanan bu yapı iki esas katmandan oluşur.

Diğer taraftan rüzgâr zaman serileri yerine direkt olarak rüzgâr güç üretim zaman serileri üzerinden NWP kullanmadan güç üretim tahmini yapan yaklaşımlar da vardır [75]. Bu yaklaşımlar genellikle tek bir katmandan oluşurlar.

Her iki zaman serisi yaklaşımı da esas olarak sadece zaman serileri kullandıkları ve NWP gibi ayrıca girdiler kullanmadıkları için çok kısa süreli rüzgârdan üretilen elektriksel gücün tahmininde nispeten başarılı sonuçlar üretebilirken, özellikle kısa süreli (6 saat-72 saat) tahminlerde yetersiz kaldıkları için başarılı sonuçlar verememektedirler.

2.3.2. NWP Kullanan Temel İstatistiksel Yaklaşımlar

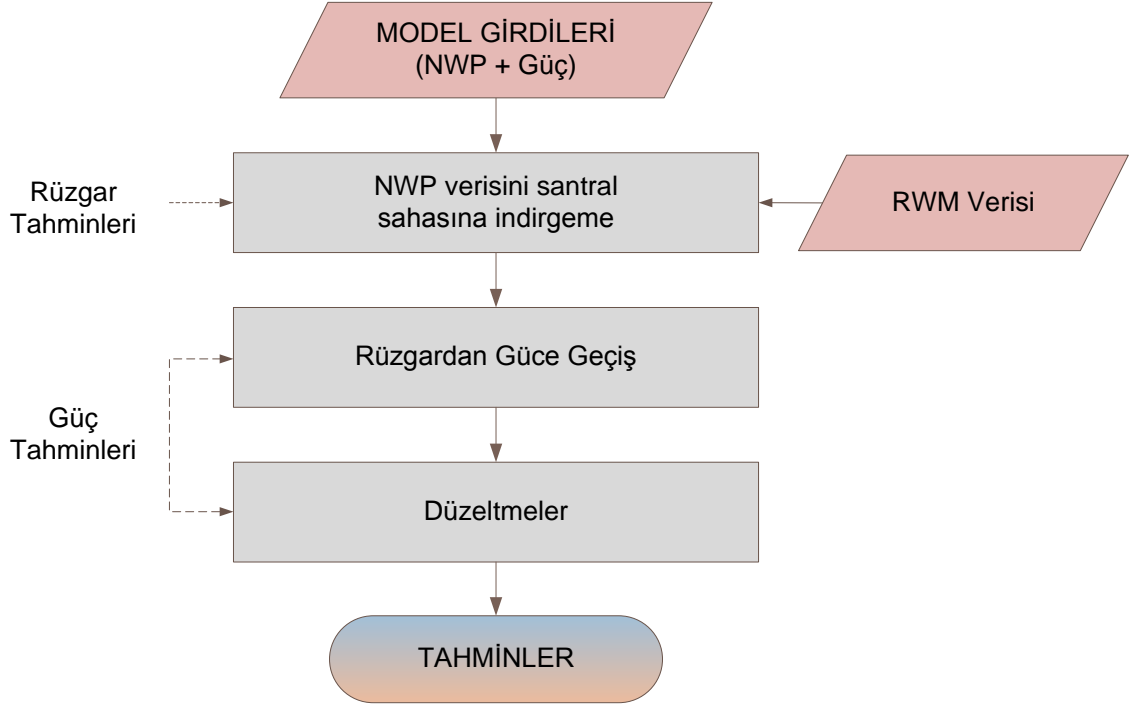
Girdi olarak NWP verilerini kullanan modeller, kısa süreli tahminlerde NWP kullanmayan modellere oranla çok daha başarılı sonuçlar vermektedir. NWP rüzgâr verilerinin hata miktarlarına bağlı olarak tüm modelin hata oranları da değişmektedir. Kısa süreli tahminlerde 72 saate kadar olan NWP tahminleri tek katmanla arada rüzgâr ile üretim ilişkisini öğrenen model ya da modeller kullanılarak güç tahminlerine dönüştürülebilir. Aynı zamanda çoklu NWP verisi, çoklu katman yapısı kullanarak rüzgâr tahminlerine dönüştürülürler [44], [77]. İleri istatistiksel modellerde çoklu NWP girdi yapısı katman sayısı hatayı minimize edecek şekilde artırılarak güç üretim tahminleri elde edilir. Bu yaklaşımları temsil eden blok şema Şekil 2.3'te verilmiştir.



Şekil 2.3 NWP tabanlı temel istatistiksel tahmin modeli blok şeması

2.4. RWM Tabanlı Temel İstatistiksel Modeller

NWP tabanlı modellerin rüzgârdan üretilen elektriksel güç tahminlerinin iyileştirilmesi için santralin gerçek rüzgâr ölçüm verilerini içeren ve santral sahasını iyi temsil eden RWM verileri kullanılmaktadır. NWP verileri önce ara bir katmanda RWM verileri ile santral sahasına indirgenirken sonraki katmanlarda nihai güç tahminlerine dönüştürülür. İyileştirilmiş NWP verilerini kullanarak güç tahminleri yapmak daha başarılı tahmin sonuçlarının elde edilmesini sağlamaktadır. Ancak RWM kurulumu oldukça maliyetli bir işlem olduğu için literatürde çok fazla çalışmada yer almadığı görülmüştür. Özellikle sadece ticari olarak geliştirilen tahmin sistemlerinde kurulabilen RWM'ler, tahmin iyileştirilmesinde uygun yöntemlerle kombine edildiklerinde oldukça başarılı sonuçlar verebilmektedir. RWM tabanlı örnek bir tahmin yöntemi akış şeması Şekil 2.4'te verilmiştir.



Şekil 2.4 RWM tabanlı örnek bir tahmin modeli

3. RÜZGÂRDAN ÜRETİLEN ELEKTRİKSEL GÜCÜN ÇOK KATMANLI YAPIYLA TAHMİNİ


Tezin bu bölümünde, gerçek zamanlı, iyileştirilmiş, kısa-dönem rüzgârdan üretilen elektriksel gücün tahmini için çoklu NWP girdi verisi ile çeşitli ANN ve SVM model kombinasyonlarını kullanan, her bir WPP için yeni bir, çok katmanlı, kademeli istatistiksel model oluşturulmuştur. Model içinde ortaya çıkarılan ara ANN ve SVM model tahminleri her bir WPP için ağırlıklandırma faktörleri ile kombine edilerek nihai tahminler iyileştirilmiştir.

Önerilen rüzgârdan üretilen elektriksel gücün tahmini yönteminin literatürdeki diğer istatistiksel yöntemlerden farkları ile literatüre yaptığı önemli katkılar şu şekilde ifade edilebilir:

- i) RİTM projesine dâhil olan her bir WPP için en yakın dokuz NWP grid verisi arasından en iyi gridi seçen yeni bir yaklaşım önerilmiştir. Bu yöntemde tüm ANN ve SVM modelleri santrale en yakın dokuz grid verisi ile tek tek eğitilir. Temel ANN ve SVM modelleri tüm gridler için eğitildikten sonra ve eğitim sonucunda en az eğitim hatasını veren grid en iyi grid olarak seçilir. Genelleştirme yapmak için, her bir NWP girdi verisi için bu yöntem uygulanarak n sayıda NWP girdisi için n sayıda en iyi grid seçimi yapılır.
- ii) En iyi grid seçiminden sonra, orta ölçekli modellerden elde edilmiş çoklu NWP girdisi için WPP bazında ANN ve SVM modelleri oluşturulur. Özellikle karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde bu şekilde yapılan tahminlerin daha başarılı olduğu görülmüştür. Çoklu NWP girdi yapısı, tek NWP modeli kullanarak oluşturulmuş modellerden gelen bireysel sistematik hataların giderilmesini sağlar.
- iii) NWP girdileri ile seçilmiş olan en iyi grid verisi kullanılarak ANN ve SVM modelleri ile oluşturulan ara tahminler ardışık iki kademe ile kombine edilerek nihai rüzgârdan üretilen elektriksel güç tahmin edilir. Her bir bireysel ara tahminden gelen sistematik hatalar, ağırlıklandırılmış ortalama kombinasyon yöntemiyle elenerek en az hatayı veren rüzgârdan üretilen elektriksel güç tahmini elde edilir.

3.1. Geliştirilen Modelin Tanımı

Rüzgârdan üretilen elektriksel gücün tahmini yöntemlerinden istatistiksel modeller, genellikle üç temel kategoriye ayrılır. İlk kategoride, tek katmanlı yapıyla tek NWP girdi verisi ve güç üretim girdi verisi kullanılarak, rüzgârdan-güce direk geçiş ile nihai tahminler yapılır [8]. İkinci kategorideki yöntemler ise istatistiksel model ve MOS/sınıflandırma olmak üzere iki katmandan oluşur [37], [48]. Bu yeni eklenen katman genellikle tahmin modeli içerisindeki sistematik hataların giderilmesinde kullanılır. Son kategori olan üçüncü kategoride ise, tekli ya da çoklu NWP verisi ile WPP güç üretim verisi toplanır. Daha sonra bu veriler kullanılarak çok katmanlı bir model ile rüzgârdan üretilen elektriksel gücün tahminleri yapılır [14], [38]. Çok katmanlı ve toplu modeller genellikle hataların azaltılmasında ve güç tahminlerinde daha iyi performans gösterirler. Bu tez çalışmasının ilk bölümünde geliştirilmiş olan çok katmanlı, kademeli rüzgârdan üretilen elektriksel gücün tahmini modeli için oluşturulan blok şema Şekil 3.1’de verilmiştir.




Şekil 3.1 Önerilen tahmin modeli blok diyagramı

(a) 1, 2 ve 3. Kademeler (b) 4 ve 5. Kademeler (RG: Rüzgârdan Üretilen Elektriksel Güç)

Geliştirilen çok katmanlı ve kademeli grup tahmin modeli sırasıyla: en iyi grid seçim katmanı (Katman 1), çoklu ANN ve SVM tahmin katmanı (Katman 2), MOS düzeltme katmanı (Katman 3), ara ANN ve SVM tahminleri kombinasyon katmanı (Katman 4) ve nihai kombinasyon katmanı (Katman 5) olmak üzere beş temel katmandan oluşmaktadır. Model, her bir WPP için başarılı bir şekilde, n sayıda orta ölçekli NWP girdi verisi ile güç üretim verisine uygulanmıştır. Elde edilen nihai tahminler saatlik çözünürlükte, 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleridir. Her bir katman ayrıntılı olarak şöyle açıklanabilir:

Katman 1: Bu katmanda her bir NWP modeli için en iyi meteorolojik grid verisi seçilir. Bu seçim için WPP çevresindeki NWP modellerinin her birine ait 100 meteorolojik grid noktasından saatlik çözünürlükte rüzgâr hızı ve yönü değerlerini içeren n farklı NWP verisi (bu uygulamada $n=3$) elde edilir. Bu 100 gridden, WPP'leri ve santral sahasını en iyi temsil eden, santrale en yakın dokuz grid verisi eğitim aşamasında kullanılmak üzere Şekil 3.2'de gösterildiği gibi alınır. Bu, n farklı NWP modelinin her biri için dokuz grid verisi temel düzeyde oluşturulmuş ANN ve SVM modelleri ile eğitilir. Eğitim sırasında en az hatayı veren grid verisi ilgili model için en iyi grid olarak seçilir. En iyi grid verisi esas modellerin eğitiminde ve test aşamasında kullanılır. Sırasıyla G_{an} ve G_{sn} olarak gösterilen en iyi grid verisi esas ANN ve SVM modellerini eğitmede kullanılır. Seçilen en iyi grid verileri olan G_{an} ve G_{sn} , sırasıyla ANN ve SVM modelleri için MAE cinsinden minimum eğitim hatasını verir (MAE_{min}). MAE ve MAE_{min} hesaplamaları Eşitlik (3.1) ve Eşitlik (3.2)'de sırasıyla verilmiştir. NWP verileri için detaylar Ek-3'te verilmiştir. Grid verileri 4 km x 4 km ve 6 km x 6 km olarak iki farklı çözünürlüğe sahiptir.



Şekil 3.2 Örnek bir WPP için en iyi grid seçimi

$$MAE = \frac{1}{n} \sum_{i=1}^n |G_i - T_i| \quad (3.1)$$

$$MAE_{\min} = \min\{MAE_1, MAE_2, \dots, MAE_9\} \quad (3.2)$$

Burada, n veri sayısını, G gerçek değeri (rüzgar hızı veya rüzgar gücü), T tahmin değerini ifade etmektedir. MAE_i , $i=1,2, \dots, 9$, için i 'nci gridin MAE değerini ifade etmektedir.

Katman 2: Birinci katmanda n adet NWP verisinin her biri için elde edilen, rüzgâr hızı ve yönü değerlerini içeren en iyi grid verisi, ANN ve SVM modellerinin eğitiminde kullanılır. Her bir WPP'den alınan rüzgârdan üretilen elektriksel güç verisi ise eğitim aşamasının çıktı verisi olarak kullanılır. Test aşamasında ise oluşturulan model parametreleri ile en iyi grid verisi kullanılarak ANN ve SVM model çıktıları ayrı ayrı değerlendirilerek gerçek üretim verisi ile karşılaştırılır, tahmin performansı WPP bazında incelenir.

Katman 3: Önerilen modelin ikinci katmanında var olan sistematik hatalar MOS kullanılarak minimize edilir. Eğitim aşamasında, WPP'lerden elde edilen gerçek üretilen güç değerleri ile tahmin sonuçları karşılaştırılarak MOS parametreleri belirlenir ve test aşamasında kullanılmak üzere kaydedilir. Bu kademe sonucunda elde edilen $2n$ sayıdaki tahminler ise 48-saat öncesi ara ANN ve SVM tahminleri olarak adlandırılırlar.

Katman 4: Düzeltilmiş n farklı ara ANN tahminleri kombine edilerek tek bir ANN tahminine dönüştürülürken, n farklı ara SVM tahminleri de kombine edilerek tek bir SVM tahminine dönüştürülür. Bu kombinasyon katmanında, eğitim ve test aşamasında sırasıyla Eşitlik (3.3) ve Eşitlik (3.4)'teki eşitlikler kullanılır.

$$\underset{w_{(a/s)i}}{\text{Minimize}} = \sum_{t=T-\lambda}^{T-1} \sum_{h=1}^{48} \left| A_{t,h} - \frac{1}{n} \sum_{i=1}^n w_{(a/s)i} F_{(a/s)i,t,h} \right| \quad (3.3)$$

$$F_{(a/s),t,h} = \frac{1}{n} \sum_{i=1}^n w_{(a/s)i} F_{(a/s)i,t,h} \quad (3.4)$$

burada, T tahmin başlangıç günü, λ eğitim uzunluğunu gösteren gün sayısı, t gün indeksi, h saat indeksi, n ANN/SVM tahmin sayısı, A gerçek rüzgârdan üretilen elektriksel güç üretim verisi, $F_{(a/s)}$ a/s indisleri ANN/SVM modellerini ifade etmek üzere rüzgârdan üretilen elektriksel güç tahmini ve $w_{(a/s)i}$ i 'nci ANN/SVM modeli ağırlık değeri, olarak tanımlanabilir.

Eşitlik (3.3)'te başlangıç olarak ağırlık katsayısı 1'e ayarlanır ve bu değer 0.1 büyüklüğündeki adımlar kullanılarak her bir ANN ve SVM modeli tahmininin saatlik çözünürlükte en az hatayı verdiği 0-3 aralığındaki ağırlık değerlerine dönüştürülür. Sonuçta elde edilen nihai ağırlık katsayıları Eşitlik (3.4)'te kullanılarak, ağırlıklandırılmış ortalamalı ara 48-saat öncesi tahminler elde edilir.

Katman 5: Son katmanda, iki adet 48-saat öncesi ara ANN ve SVM model tahminleri son kombinasyon modeli ile kombine edilerek nihai 48-saat öncesi rüzgâr üretim tahminlerine ulaşılır. Eğitim ve test aşamasında sırasıyla Eşitlik (3.5) ve (3.6) kullanılır.

$$\underset{w_{fa}, w_{fs}}{\text{Minimize}} = \sum_{t=T-\lambda}^{T-1} \sum_{h=1}^{48} \left| A_{t,h} - \frac{1}{2} (w_{fa} F_{a,t,h} + w_{fs} F_{s,t,h}) \right| \quad (3.5)$$

$$F_{f,t,h} = \frac{1}{2} (w_{fa} F_{a,t,h} + w_{fs} F_{s,t,h}) \quad (3.6)$$

burada, w_{fa} ve w_{fs} sırasıyla ANN ve SVM modeli tahminlerinin nihai kombinasyon katsayılarını ve F_f ise nihai rüzgârdan üretilen elektriksel güç tahminini ifade etmektedir.

Katman 4'teki eğitim aşamasında her bir ANN/SVM tahmin modeli için ağırlık katsayıları ($w_{(a/s)i}$) belirlenir. Bu değerler gerçek zamanlı tahmin ya da test aşamasında ara tahminlerin elde edilmesinde kullanılır. Biri ANN için diğeri de SVM için olan iki ara tahmin, Katman 5'te Eşitlik (3.5) ve Eşitlik (3.6) kullanılarak nihai tahminlere dönüştürülür. Katman 4 ve 5'te kullanılan ağırlık katsayıları ($w_{(a/s)i}$, w_{fa} ve w_{fs}), ağırlıklandırılmış ortalama kombinasyon yöntemi ile bulunur.

Eşitlik (3.3) ve (3.5)'teki ağırlık katsayılarını belirlerken, eğitim aşamasında verinin ilk yarısı değerleri belirlemede kullanılırken, diğeri yarısı ise bu değerlerin doğrulamasında kullanılır. Eşitlik (3.3)'te $2n$ sayıda farklı ağırlık katsayısı varken, Eşitlik (3.5)'te ise biri ANN modeli tahmini için diğeri SVM modeli tahmini için olmak üzere sadece iki tane ağırlık katsayısı vardır.

3.2. Geliştirilen Modelin Uygulanması

2010 yılında, rüzgârdan üretilen elektriksel gücün tahmini alanında, Türkiye'de Rüzgârdan Üretilen Elektriksel Güç İçin İzleme ve Tahmin Sistemi Geliştirilmesi Projesi (RİTM) başlığıyla, gelişmiş ulusal çapta bir proje yapılmıştır [75]. RİTM projesinin temel tahmin yaklaşımı, WPP sahiplerinin yanında iletim ve dağıtım operatörlerini de hedef olarak görmektedir. Proje, günümüzde çok sayıda WPP'nin sisteme entegrasyonunu sağlarken bu büyük çaptaki entegrasyonun gelecekteki muhtemel sorunlarının belirlenmesinde de öncü


rol oynamaktadır. Hali hazırda sisteme bağlı tüm WPP'ler gerçek zamanlı izlenebilirken, diğer taraftan ölçümü yapılan rüzgârdan üretilen elektriksel güç verisi, meteorolojik ölçüm verileri ve NWP verileri kullanılarak saatlik çözünürlükte çok kısa süreli (6 saate kadar) ve kısa süreli (48 saate kadar) rüzgârdan üretilen elektriksel güç tahminleri yapılmaktadır.



Bu tez çalışması kapsamında gerçekleştirilen gerçek zamanlı çok katmanlı, rüzgârdan üretilen elektriksel gücün tahmini modeli, proje içerisinde üç farklı NWP modeli ile sağlanan 48-saat öncesi rüzgâr tahmin verileri ve her bir WPP'ye bağlanmış Rüzgâr Enerjisi Analizörleri (WEA) sayesinde [77] elde edilen üretim verilerini kullanarak saatlik çözünürlükte 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri yapılır.

3.2.1. Uygulanan Santraller

Geliştirilen model Türkiye'deki RİTM sistemine bağlı 25 santralde uygulanmıştır. Bu santraller ülkedeki rüzgârdan üretilen elektriksel gücün önemli bir kısmını temsil etmektedir. Santral konumları ile kurulu güçleri Türkiye haritası üzerinde Şekil 3.3'te gösterilmiştir. Düz arazi yapısı ile daha az dağınık rüzgâr karakteristiğine sahip santraller sadece proje logosu ile gösterilirken, karmaşık arazili dağınık rüzgâr rejimli santraller ise rüzgârgülü grafikleri ile birlikte verilmiştir.

Santrallerin kurulu güç kapasiteleri, rüzgâr türbin sayıları ile RİTM projesine dâhil olma yılları Çizelge 3.1'de verilmiştir. Gri renkte gösterilen satırlar karmaşık araziye ve dağınık rüzgâr rejimine sahip santralleri göstermektedir. Bu tez çalışmasında incelenen rüzgâr santralleri farklı arazi yapısına ve rüzgâr davranışına sahiptir.




Şekil 3.3 RİTM projesindeki 25 santralin konumları, , proje logosunu, , karmaşık arazili santrallerin rüzgârgülünü ve Pinst santral kurulu gücünü göstermektedir

Çizelge 3.1 Rüzgâr santrallerinin kurulum bilgileri
(Gri gölgeli kısımlar karmaşık arazili santralleri göstermektedir)

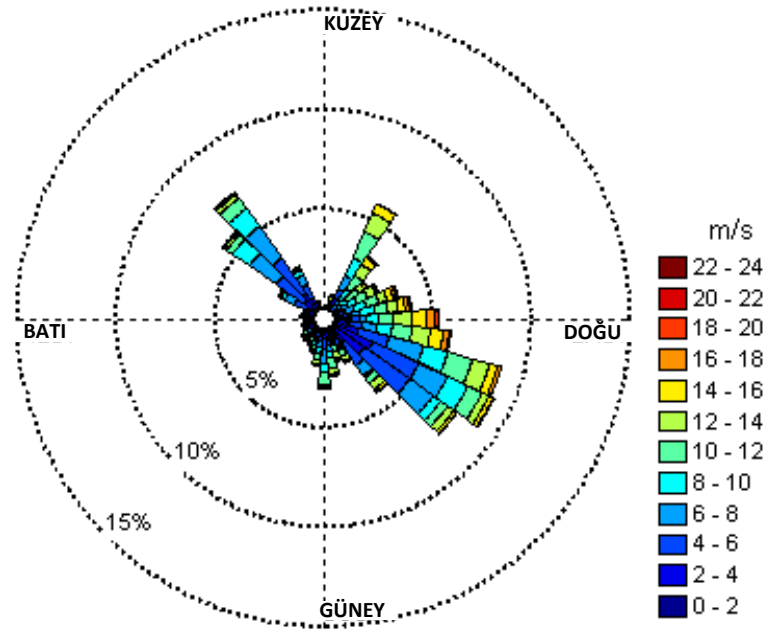
<i>Santral Numarası</i>	<i>Türbin Sayısı</i>	<i>Kurulu Güç (MW)</i>	<i>RITM katılım tarihi</i>
WPP1	5	15	2010
WPP2	36	90	2010
WPP3	20	60	2010
WPP4	22	35	2011
WPP5	17	10.2	2010
WPP6	18	14.9	2010
WPP7	49	39.2	2010
WPP8	54	135	2011
WPP9	98	140.1	2010
WPP10	16	48	2011
WPP11	15	30	2012
WPP12	16	35	2012
WPP13	23	76.25	2012
WPP14	5	12	2012
WPP15	36	72	2013
WPP16	16	39	2013
WPP17	20	60	2013
WPP18	16	40	2013
WPP19	16	39	2013
WPP20	34	78.2	2014
WPP21	38	114	2014
WPP22	70	150	2014
WPP23	10	25	2014
WPP24	14	34	2014
WPP25	52	142.5	2014
TOPLAM	716	1534.35	

Örnek iki WPP için 2012-2013 yılları için elde edilmiş yaklaşık iki yıllık veri kullanılarak çizilen rüzgârgülü grafikleri Şekil 3.4'te verilmiştir. Şekil 3.4 (a), düz araziye sahip WPP2 santralının rüzgârgülü grafiğini gösterirken, Şekil 3.4 (b) ise karmaşık bir arazi yapısı ile dağınık rüzgâr karakteristiğine sahip WPP10 santraline ait rüzgârgülü grafiğini göstermektedir. Tüm santrallerin rüzgârgülü grafikleri EKLER bölümünde Ek-4'te verilmiştir.

Rüzgârdan üretilen elektriksel gücün tahmini çalışmalarında, genellikle karmaşık arazi yapısı ve dağınık rüzgâr karakteristiğine sahip santrallerin tahminleri daha gelişmiş doğrusal olmayan tahmin modelleri ile daha başarılı sonuçlar verebilmektedir. Nitekim geliştirilen ileri istatistiksel model, karmaşık yapıya sahip santrallerde başarılı bir şekilde uygulanmıştır.



(a)



(b)

Şekil 3.4 İki farklı santral için rüzgârgülü grafikleri
(a) düz araziye sahip WPP2 (b) karmaşık araziye sahip WPP10

3.2.2. ANN Model Yapısı ve Parametre Seçimleri

Yapay sinir ağları doğrusal olmayan aktivasyon fonksiyonları doğrusal bağlanım yeteneği olan ve temel elemanı nöron olarak adlandırılan yapılardır. Bir nöronun çıktı değerleri bu doğrusal olmayan aktivasyon fonksiyonları sayesinde modellenebilir. Geliştirilen model içerisindeki ANN yapısında kullanılan k 'inci nöronun toplam çıktı fonksiyonu v_k , Eşitlik (3.7)'de şöyle ifade edilebilir.

$$v_k = b_k + x_1w_1 + x_2w_2 + \dots + x_Nw_N = \sum_{j=1}^N x_jw_j + b_k \quad (3.7)$$

burada, x_j girdi verisini, w_j ağırlık katsayılarını, N eğitim girdi veri sayısını ve b_k ise k 'inci nöron için bias terimini göstermektedir. Toplam fonksiyonu v_k , Eşitlik (3.8)'de gösterildiği gibi aktivasyon fonksiyonu ϕ 'den geçirilir.

$$y_k = \phi(v_k) \quad (3.8)$$

burada, y_k , k 'inci nöronun çıktı değerini göstermektedir. Eğitim aşamasında, her bir iterasyonda elde edilen çıktı değeri hedef değerle karşılaştırılarak nöronun çıktı hatası hesaplanır. Daha sonra hatayı minimize edebilmek için geri bildirim ile bu hatalar önceki katmanlara iletilerek ağırlık ve bias değerleri değiştirilir. Rüzgârdan üretilen elektriksel güç üretimi pozitif bir değere sahip olduğu için sadece pozitif değerler alan bir aktivasyon fonksiyonu kullanmak daha iyi tahmin sonuçlarına ulaşmayı sağlar. Bu nedenle ANN modeli içerisinde sigmoid aktivasyon fonksiyonu kullanılmıştır.

Rüzgârdan üretilen elektriksel güç üretim tahmin problemlerinde, rüzgâr hızı/yönü değerleri ile rüzgâr üretim güç değerleri arasındaki doğrusal olmayan ilişkiden dolayı, ANN modellerinin kullanımı uygundur. Buradaki en kritik nokta ise en uygun yapı ve parametreleri kullanmaktır. Aksi halde uygun olmayan ANN yapıları ve parametreleri, tahmin hatalarının kabul edilemeyecek kadar yüksek değerlere ulaşmasına neden olabilmektedir [79]

Geliştirilen yöntemde, üç katmanlı ileri beslemeli bir ANN yapısı kullanılmıştır. Üç katman sırasıyla girdi katmanı, gizli katman ve çıktı katmanı olarak tanımlanır. Tek bir gizli katman girdi/çıktı ilişkisini belirlemede yeterli başarı sağladığı için ANN yapısının karmaşık ve ağır olmaması amacıyla çoklu gizli katman kullanılmamıştır.

ANN model yapısı ve parametreleri, kontrollü öğrenme yöntemi ile bilinen girdi-çıktı veri kümesi kullanılarak belirlenmiştir. Hem katman sayısı hem de nöron sayısı, bilinen veri

üzerinde yapılan eğitimlerle deneme yanılma yöntemi ile optimize edilmiştir. Özellikle model performansını en çok etkileyen değişkenlerden biri olan nöron sayısı, birçok sayı aralığı için farklı katman sayısı ve aktivasyon fonksiyonu ile denenerek modelin en düşük hatayı verdiği nöron sayısına ulaşılmaya çalışılmıştır. Özellikle gizli katmandaki nöron sayısını en uygun değerine getirebilmek için santral bazında NWP girdisine göre değişen sayılarla kontrollü eğitimler yapılmıştır. Nöron sayısının yetersiz seçilmesi durumunda, ANN modeli veriyi tam olarak uygun bir şekilde modelleyemediği için tahmin hatası yüksek çıkmaktadır. Diğer taraftan gizli katman nöron sayısının olması gerekenden fazla olması durumunda ise model eğitim verisini ezberleyerek test verisinde daha fazla hata yapmaya başlamaktadır. Bu aşamada hatayı minimize eden nöron sayısı ve gizli katman sayısı esas model parametresi olarak kaydedilmiştir.

Üç katmanlı ANN yapısında, girdi katmanı için iki nöron (rüzgâr hızı ve yönü girdileri için), gizli katman için 6-35 aralığında değişen nöron sayısı, çıktı için ise bir nöron (rüzgârdan üretilen elektriksel güç üretim çıktısı için) kullanılmıştır. Her bir santral için santral karakteristiği ve veri yapısına göre iyi bir tahmin elde edebilmek için kullanılan gizli katman nöron sayısı farklılık göstermektedir. Veri sayısı az olan ve santral bölgesinde az değişken rüzgâr karakteristiği olan santrallerde daha az sayıda gizli katman nöronu kullanılmıştır. Diğer taraftan veri sayısı fazla olan ve santral rüzgâr karakteristiği çok değişken olan santrallerde kullanılan ANN modeli için gizli katman nöron sayısı yüksek seçilmiştir. ANN modeli eğitim aşaması boyunca, model performansı ve ağırlık/bias değerlerini belirlemede ortalama kare hata (MSE) kriteri kullanılmıştır. Eğitim fonksiyonu olarak ise öğrenme oranı katsayısı kullanmayan ve fazla eğitim verisine sahip yığın tip esnek geri yayılım metodu kullanılmıştır [79]. Kullanılan bu MSE hesaplaması Eşitlik (3.9)'da verilmiştir.

$$MSE = \frac{1}{n} \sum_{i=1}^n (G_i - T_i)^2 \quad (3.9)$$

Giriş katmanında tahmin çıkışını etkileyecek tüm veriler sisteme girdi olarak verilmektedir. Ancak rüzgâr üretim tahminlerinde üretim değerini etkileyen en önemli iki faktör rüzgâr hızı ve yönü girdileridir. Diğer değişkenler olan nem, sıcaklık gibi girdiler sistem performansında görünür bir iyileştirme sağlamadıklarından hesaba katılmamıştır. Çıkış katmanında ise tek bir çıkış değişkeni kullanılmaktadır. Bu tahmini yapılacak değişkenlere göre farklılık gösterebilir, ancak burada bu değişken direkt olarak rüzgâr gücü üretimi seçilmiştir. Gizli katman olarak ise sistem girdilerine gösterilecek tepkilere uygun


ağırlıklandırmaları yapacak uygun sayıda nöron seçilmektedir. ANN modelinin akışlarının gösterildiği ve eğitim ile test süreçlerinin detaylı bir şekilde belirtildiği akış şeması Şekil 3.5'te verilmiştir. ANN modelleri ile ilgili detaylı bilgiler Ek-2'de verilmiştir.

3.2.3.SVM Model Yapısı ve Parametre Seçimleri

SVM modelleri, sınıflandırma ve regresyon problemlerinde yüksek doğrulukta sonuçlar elde edebilmek için orijinal problemi üst boyutlara taşıyarak çözüme başarılı sonuçlar vermektedir. Bu özelliği sayesinde, alt boyuttaki doğrusal olmayan rüzgârdan üretilen elektriksel güç tahmini problemini üst boyutlara taşıyarak doğrusal yapıda iyi tahmin sonuçları verebilecek bir probleme dönüştürür. SVM regresyon problemi Eşitlik (3.10)'daki gibi tanımlanabilir.

$$O = \sum_{i=1}^P w_i K(.) + b_0 + \varepsilon \quad (3.10)$$

burada, O SVM model çıktı değerini, P , eğitim veri sayısı, w_i , ağırlık değerini, $K(.)$, kernel fonksiyonunu, b_0 bias terimini ve ε hatta terimini ifade etmektedir.



Şekil 3.5 ANN tahminleri akış şeması

Tahmin modeline bağılı olarak, ANN modelinde olduğu gibi, en uygun SVM model yapısı ve parametrelerini seçmek iyi bir tahmin çıkarmak için kritik öneme sahiptir. SVM modeli için tahmin sonuçlarını en çok etkileyen değişkenlerden biri olan kernel fonksiyonu, rüzgârdan üretilen elektriksel güç tahminlerine uygun iyi sonuçlar veren Radyal Tabanlı Fonksiyon kullanılmıştır [81]. Bu fonksiyon Eşitlik (3.11)'de gösterilmiştir.

$$K(x_j, x_i) = \exp\left(-\gamma \|x_j - x_i\|^2\right), \quad \gamma > 0 \quad (3.11)$$


burada, γ kernel parametresini, x_j ve x_i ise eğitim verisi için örnek ve örneğe ait etiket kümesini ifade etmektedir. İyi bir tahmin için kernel parametresinin probleme uygun seçilmesi kritik bir önem taşır. Eğitim aşaması sonrasında doğrulama safhasında tekrarlamalı işlemlerle hata karesini minimum yapan SVM modeli için hata ceza parametresi [81] ve γ parametresi bulunur ($\gamma=2$). Kullanılan SVM modelinin genel akış şeması aşağıda Şekil 3.6'da özetlenmiştir. SVM modelleri ile ilgili detaylı bilgiler Ek-2'de verilmiştir.

Elde edilen ANN ve SVM model yapıları ile parametreleri kaydedilir ve öncelikle tüm eğitim verisi ile eğitim aşamasından geçirilir. Daha sonra test aşamasında her bir WPP için 48-saat öncesi rüzgârdan üretilen elektriksel gücün tahminlerinde bu parametreler çağrılarak geliştirilen model içinde kullanılır.

3.2.4. Model İçin Kullanılan Girdiler ve Çıktılar

Geliştirilmiş modelin NWP verilerine uygulanmasına başlamadan önce, Avrupa Orta-ölçekli Hava Tahmin Merkezi (ECMWF) ve Global Tahmin Sistemi (GFS) tarafından başlangıç koşulları belirlenen NWP meteoroloji verisini daha yüksek bir çözünürlüğe dönüştürmek için işlemler yapılır. Bu dönüştürme aşamasında Hava Araştırma ve Tahmin (WRF) orta ölçekli modeli kullanılarak, meteoroloji verisi 6 km x 6 km çözünürlükte 100 grid noktası verisine kadar dönüştürülürken, ALADIN (Aire Limitée Adaptation dynamique Développement InterNational) orta ölçekli modeli kullanılarak meteoroloji verisi, 4 km x 4 km çözünürlükte 100 grid verisine kadar dönüştürülür.

Bu tez çalışmasında NWP1, NWP2 ve NWP3 olarak adlandırılan üç farklı NWP verisi kullanılmıştır. Burada NWP1, Devlet Meteoroloji İşleri (DMI), NWP2, GFS modeli ve NWP3, ECMWF modeli tarafından elde edilmiş NWP verilerini ifade etmektedir. Geliştirilen model her üç modelden gelen rüzgâr hız ve yön bilgilerini eğitim ve test aşamasında kullanmaktadır. Kullanılan tüm veriler için çözünürlük bir saattir. Ölçülen



Şekil 3.6 SVM tahminleri akış şeması

rüzgârdan üretilen elektriksel güç değerleri ise eğitim aşamasında kullanılarak tüm kademelerin parametrelerinin belirlenmesinde rol oynar. Her bir WPP için gerçek rüzgârdan üretilen elektriksel güç verilerine ulaşmada Rüzgâr Enerjisi Analizörleri (WEA) kullanılır [75]. Bu analizörler, her bir WPP’de kurulu olarak gerçek zamanlı rüzgârdan üretilen elektriksel güç üretim verilerini kanal başına 25.6 kHz örnekleme hızında örnekleyerek geliştirilen modelin kullandığı sunuculara gönderir.

3.2.5. Veri Normalizasyonu ve Tahmin Hata Tanımı

ANN ve SVM modellerinde girdi verisinin normalize değerlere dönüştürülmesi modelin performansı açısından kritik öneme sahiptir. Normalizasyon ile eğitim aşamasında yüksek değerlere sahip girdi verisinin diğer girdilere baskın olmasının önüne geçilmesi amaçlanmaktadır. Bu kapsamda geliştirilen metot içerisinde tüm eğitim verileri 0-1 aralığına normalize edilmiştir. Bu normalizasyon yöntemi olarak Eşitlik (3.12)’deki hızlı ve doğru sonuç veren yöntem uygulanmıştır.

$$\bar{v} = \frac{v - v_{\min}}{v_{\max} - v_{\min}} \quad (3.12)$$

burada, v ham veriyi, v_{\min} ve v_{\max} ise sırasıyla verinin minimum ve maksimum değerlerini ifade etmektedir. \bar{v} ise normalize edilmiş sonuç verisini vermektedir. Eğitim aşamasında elde edilen bu maksimum ve minimum değerler test aşamasında ve gerçek zamanlı tahminlerde kullanılmak üzere RİTM projesi sunucularına kaydedilmektedir.

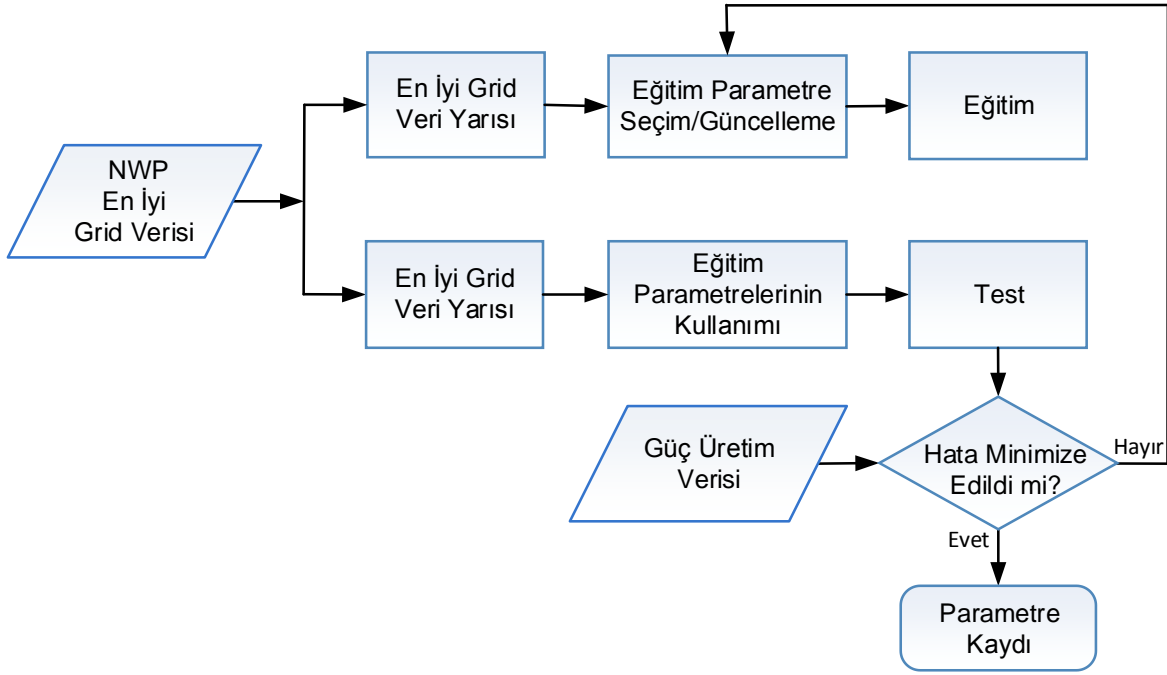
Bu tez çalışmasında elde edilen rüzgârdan üretilen elektriksel gücün tahmini hataları Eşitlik (3.13)'de verildiği gibi NMAE cinsinden hesaplanmıştır.

$$NMAE = \frac{1}{P_{inst}} \frac{1}{N} \sum_{n=1}^N |A_n - F_n| \quad (3.13)$$

burada, A_n ve F_n sırasıyla gerçek değeri ve tahmin edilen değeri ifade etmektedir. Farklı santrallerden elde edilen MAE değerlerinin karşılaştırılabilmesi için bu değer santrallerin kurulu güçlerine bölünerek Normalize MAE (NMAE) değerleri elde edilir.

3.2.6. Metodun Uygulanması

Her bir NWP grid verisi için bir ANN ve bir SVM modeli olmak üzere toplamda üç ANN ve üç SVM modeli eğitim aşamasında WPP'ye en yakın dokuz grid verisi için uygulanır. İkinci aşamada NWP1, NWP2 ve NWP3 için bulunan en iyi grid verileri normalize değerlere dönüştürülerek esas ANN ve SVM modellerinin kullanımı için hazırlanır. Normalizasyonda kullanılan değerler, test aşamasında ve gerçek zamanlı tahminlerde kullanılmak üzere veri tabanına kaydedilir. Bu aşamada Şekil 3.7'de gösterildiği çapraz-doğrulama yöntemi ile ANN ve SVM yapılarının parametreleri doğrulanır. Bu doğrulama işleminde, birinci aşamada bulunan en iyi grid verisi iki eşit parçaya ayrılır. Parçalardan biri ön eğitim aşaması olarak parametrelerin başlangıç değerleri kullanılarak optimize edildiği ilk aşamada kullanılır. Verinin diğer kısmı ise, eğitim aşamasında belirlenen değerlerin hiç görülmemiş bir veri kümesi üzerinde göstereceği performansı ölçerek, parametrelere doğrulama işlemi yapar ve istenen optimum değerlere ulaştırır. Bu doğrulama işlemi sırasında parametreler için değer aralıkları belirlenir ve bu aralıklar üzerinde tekrarlamalı olarak model performansları doğrulanır. En az hatayı veren parametre değerleri çapraz-doğrulama aşamasıyla belirlenmiş olur.



Şekil 3.7 Çapraz-doğrulama yöntemiyle ANN/SVM parametre seçimi

Eğitim aşamasında, Katman 2’den gelen tahminler Katman 3’te MOS aşamasından geçirilir. Bu aşamada MOS parametreleri belirlenirken eğitim verisi 2 eşit parçaya ayrılır. İlk parça verilerin başlangıç değerlere atandığı ve ilk optimize edilmiş değerlerin bulunduğu ön eğitim aşamasından geçirilir. Daha sonra verinin ikinci parçası kullanılarak çapraz doğrulama ile olası parametre değerleri tekrarlamalı yöntemle nihai değerlere dönüştürülür. Burada elde edilen düzeltme katsayıları, esas test aşamasında ve gerçek zamanlı tahminlerde kullanılmak üzere veri tabanına kaydedilir. Katman 3’ün çıkışında üç NWP girdisi kullanıldığı durumda, üç adet ANN ve üç adet SVM tahmini olmak üzere toplam altı düzeltilmiş ara tahmin elde edilmiş olur.

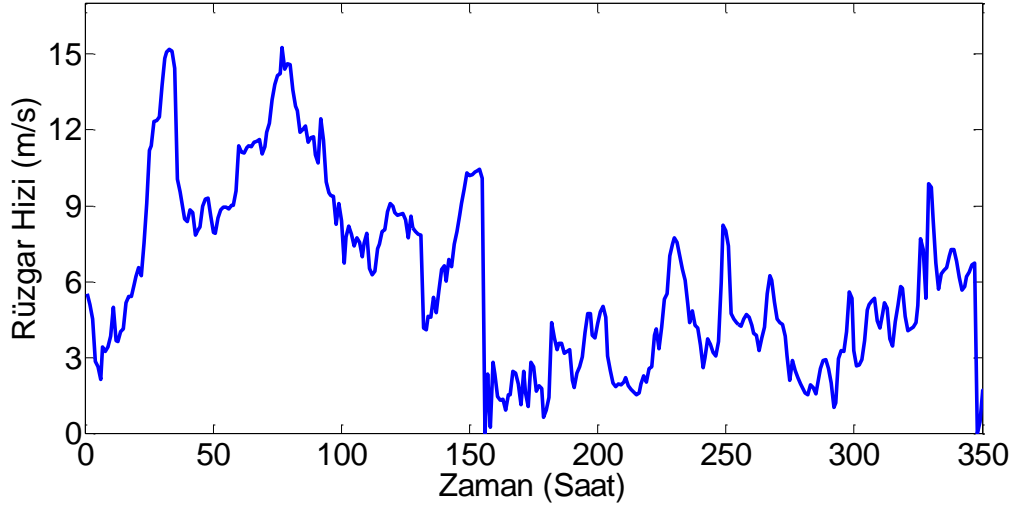
Katman 4’te, üç ANN ara tahmini uygun katsayılarla kombine edilerek tek bir ara ANN tahminine dönüştürülür. Benzer şekilde üç SVM ara tahmini de uygun katsayılarla kombine edilerek tek bir ara SVM tahminine dönüştürülür. Her bir kombinasyonun ayrı ayrı yapılması model bazında bireysel hataların düzeltilmesine katkı sağlamaktadır. Son kademedede ise iki ara tahmin sonucunu kombine ederek nihai tahminlere dönüştüren yeni bir kombinasyon yapısı uygulanır. Böylece geliştirilen çok katmanlı, basamaklandırılmış model ile nihai 48-saat öncesi rüzgârdan üretilen elektriksel gücün üretim tahminine ulaşılmış olur.

Geliştirilen modelin iyi tahmin sonuçları verebilmesi için eğitim verisinin yeterli büyüklükte olması gerekir. Süreklilik modeli dâhil diğer tahmin modellerinden daha iyi tahmin sonucu elde edebilmek için en az 12 aylık eğitim verisine ihtiyaç vardır. Özellikle karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde tahmin doğruluğu eğitim verisinin büyüklüğü ile paralel olarak artmaktadır. Ayrıca birden fazla NWP kullanımı bireysel NWP hatalarını minimize ederek daha doğru tahminler elde edilmesini sağlamaktadır.

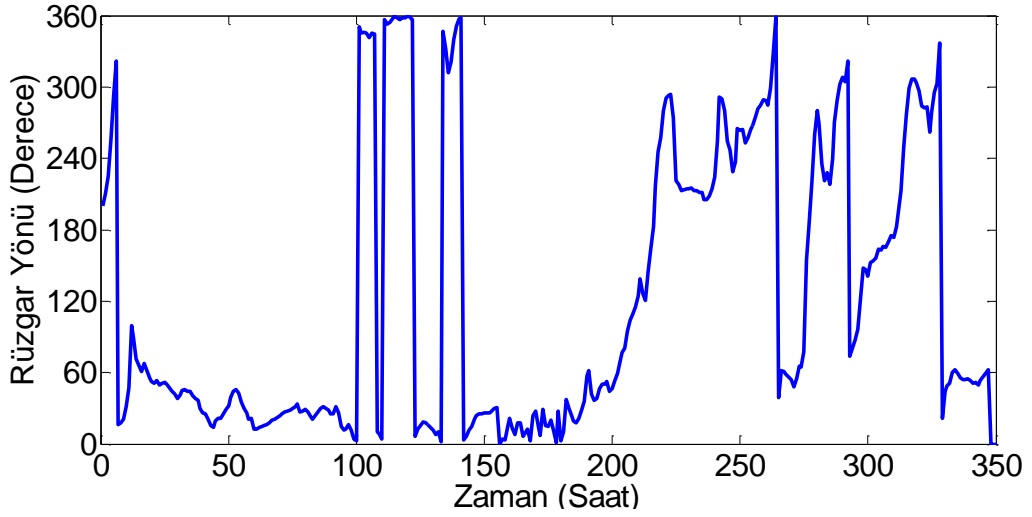
3.3. Geliştirilen Model Sonuçları

Türkiye’de 25 santral için geliştirilen model uygulanmış ve sonuçlar değerlendirilmiştir. WPP1’den WPP14’e kadar tüm santraller için eğitim verisi yaklaşık 24 ay büyüklüğünde iken, RİTM sistemine geç dâhil olmaları nedeniyle WPP15’ten WPP25’e kadar olan santrallerde eğitim verisinin büyüklüğü 3 ile 15 ay arasında değişmektedir. Test uzunluğu olarak ilk 14 WPP için 5 aylık bir süre belirlenmişken, kalan diğer WPP’lerde (WPP15-WPP25) ise 3 ay olarak belirlenmiştir.


Örnek bir WPP’ye ait iki haftalık zaman aralığı için sayısal hava tahminlerinden elde edilen rüzgâr hızı değişimleri Şekil 3.8’de verilmiştir. Benzer şekilde aynı santrale ait rüzgâr yönü değişimleri ise Şekil 3.9’da verilmiştir. Diğer taraftan örnek bir santral için geliştirilen model kullanılarak elde edilen rüzgârdan üretilen elektriksel güç tahmini ile gerçek üretim verileri Şekil 3.10’da verilmiştir. Yine yaklaşık iki haftalık bir zaman aralığında, 25 WPP için toplam tahmin ile gerçekleşen üretim değişimleri Şekil 3.11’de gösterilmiştir. Her iki şekilden de görüldüğü gibi tahmin ile gerçekleşen değerler arasında çok benzer bir değişim grafiği vardır. Bu durum önerilen modelin oldukça başarılı sonuçlar verdiğini göstermesi açısından önemlidir.



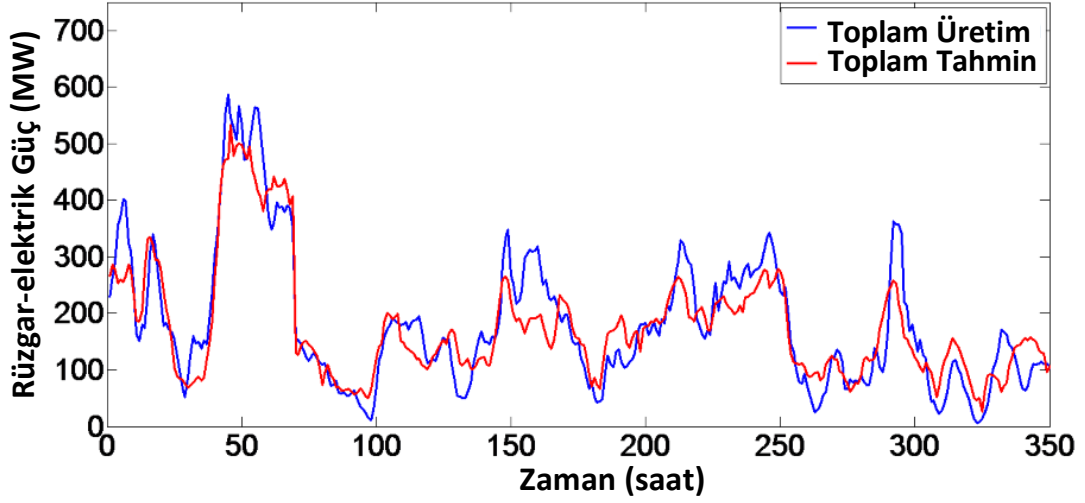
Şekil 3.8 Örnek bir WPP için rüzgâr hızı değişimleri



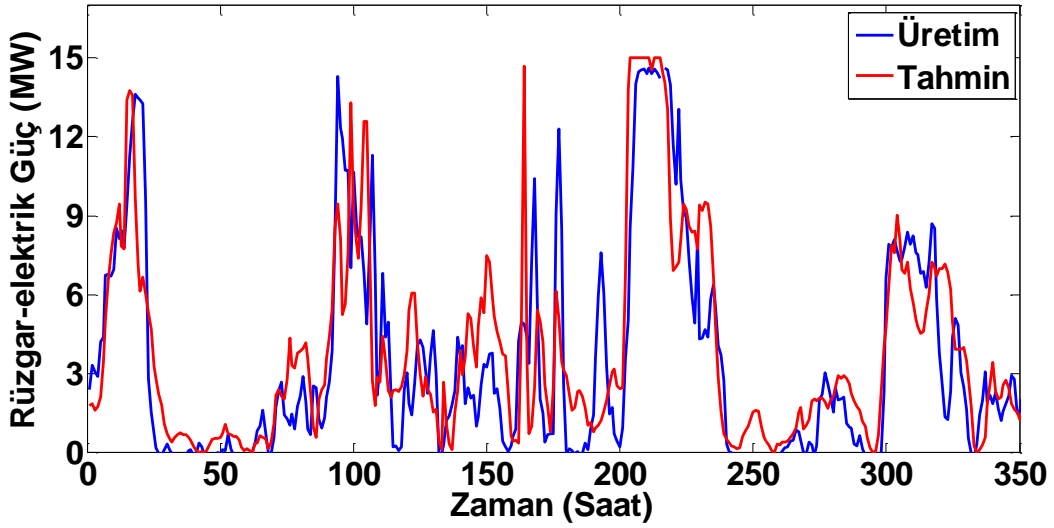
Şekil 3.9 Örnek bir WPP için rüzgâr yönü değişimleri



Şekil 3.10 Örnek bir WPP için model tahmini ve gerçek güç üretim değişimleri-1




Şekil 3.11 25 WPP için toplam tahmin ve gerçek üretim değişimleri-1



Şekil 3.12 Örnek bir WPP için model tahmini ve gerçek güç üretim değişimleri-2

Farklı bir zaman aralığında geliştirilen modelin tahmin sonuçları ile gerçekleşen üretim değişimleri örnek WPP için Şekil 3.12’de verilmiştir. Yine örnek olarak verilen ilk zaman aralında olduğu gibi bu ikinci örnek zaman aralığı için de tüm 25 WPP için toplam tahmin ile toplam gerçekleşen üretim sonuçları Şekil 3.13’te verilmiştir. Her iki farklı zaman aralığında da görüldüğü gibi tahmin eğrileri oldukça yüksek doğrulukta ve üretim eğrisine benzer değişimler göstermiştir.



Şekil 3.13 25 WPP için toplam tahmin ve gerçek üretim değişimleri-2

3.3.1. Süreklilik Metodu İle Karşılaştırma

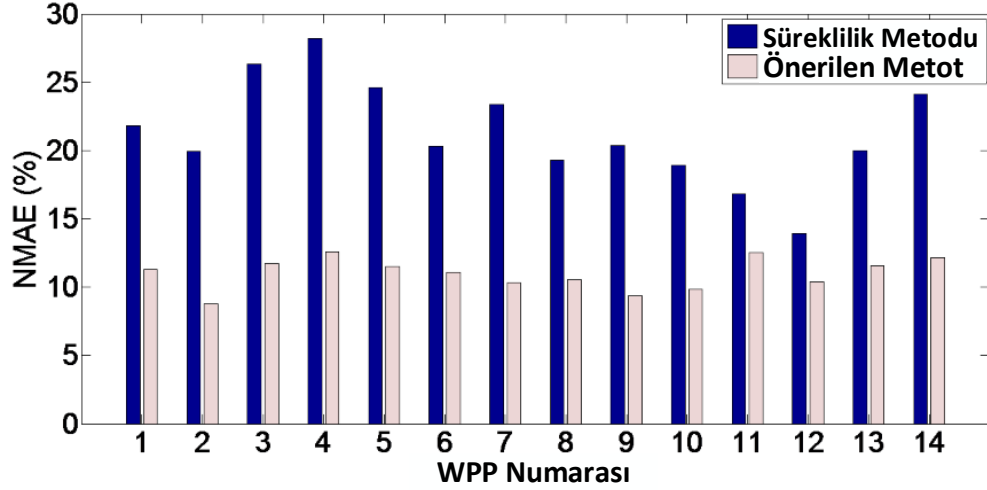
Rüzgâr hızı ve rüzgârdan üretilen elektriksel gücün tahmini çalışmalarında referans metot olarak kullanılan süreklilik metodu, geçmiş rüzgârdan üretilen elektriksel güç (ya da rüzgâr hızı) değerini kullanarak bir sonraki değeri tahmin etmek için kullanır. Genel olarak süreklilik metodu ile yapılan 48-saat öncesi rüzgâr elektrik gücü üretim tahmini Eşitlik (3.14)'te verilmiştir.

$$F_t = F_{t+1} = F_{t+2} = \dots = F_{t+48} \quad (3.14)$$

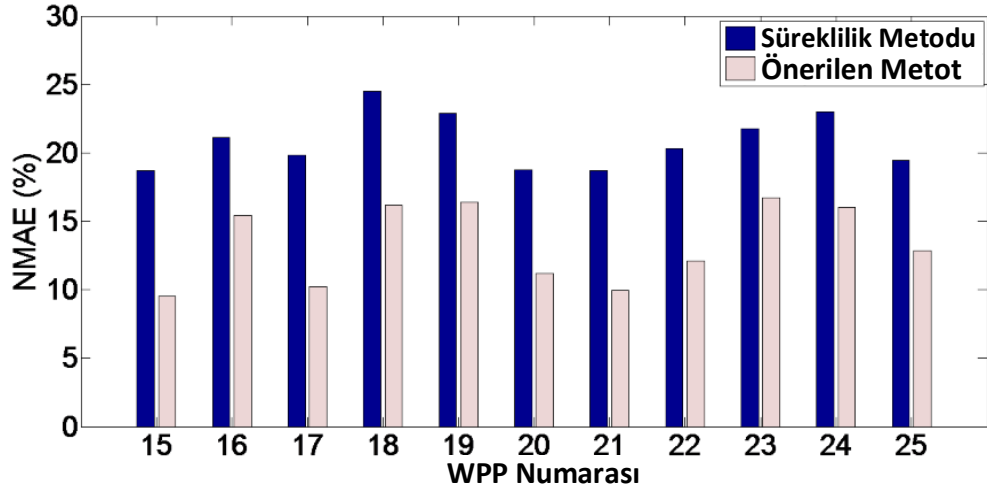
burada, F_t , t anındaki rüzgârdan üretilen elektriksel güç üretim tahminini ifade etmektedir. Bu değer saatlik çözünürlükteki adımlarla 48 saate kadarki tüm tahminlerde sabit bırakılarak 48-saat öncesi süreklilik metodu tahmini yapılmıştır. Bu tez çalışmasında ise süreklilik metodu tahminleri yapılırken Eşitlik (3.15)'te gösterildiği gibi bir sonraki değerin tahmininde, önceki 48 değerlerin ortalaması alınmıştır.

$$F_{t,mean} = ortalama (F_{t-1}, F_{t-2}, F_{t-3}, \dots, F_{t-48}) \quad (3.15)$$

Geliştirilen modelin tahmin hata sonuçları ile süreklilik metodu tahmin hata sonuçları karşılaştırılarak NMAE cinsinden Şekil 3.14'te gösterilmiştir. Görüldüğü gibi her bir WPP için geliştirilen model 48-saat öncesi tahminleri süreklilik metodu tahminlerinden daha iyi sonuç vermiştir. Süreklilik metodu üzerinde 25 WPP için % 26 ile % 56 arasında değişen bir düzeltme sağlanmıştır. Özellikle karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde bu düzeltme değeri % 40'ın üzerinde seyretmiştir. Bu sonuçlarla geliştirilen



(a)



(b)

Şekil 3.14 Önerilen metot ile süreklilik metodunun tahmin hatalarının karşılaştırılması, (a) WPP1-WPP14 için (b) WPP15-WPP25 için

modelin karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde, düz arazi ve baskın rüzgâr rejimine sahip santrallere oranla daha başarılı tahmin sonuçları verdiği görülmüştür.

3.3.2. Geleneksel Yöntemlerle Karşılaştırma


Geleneksel yöntemler, geliştirilen modelden farklı olarak daha basit yapıda ve az sayıda katman ile rüzgârdan güce geçiş yaparak rüzgârdan üretilen elektriksel güç tahmini yapan modellerdir. Bu nedenle geliştirilen modelin tahmin sonuçları ile geleneksel yöntemlerin tahmin sonuçlarının karşılaştırılması performans belirlemede önemli bir göstergedir. Geliştirilen modelin en iyi tahmin sonuçları ile tek katmanlı ANN ve SVM modelleri tahmin sonuçları karşılaştırılarak Çizelge 3.2’de gösterilmiştir. Görüldüğü gibi, geliştirilen

çok katmanlı model 48-saat öncesi tahminlerde test süresi boyunca tek katmanlı modele oranla % 1.5 ile % 5.2 aralığında değişen değerlerde daha iyi performans göstermiştir.

Örnek bir WPP için iki haftalık bir test süresince, tek katmanlı model tahmini ile çok katmanlı geliştirilen model tahminleri ve gerçek üretim değişimleri Şekil 3.15'te gösterilmiştir. Şekil 3.15'ten de görüldüğü gibi bu test süresinin büyük kısmında çok katmanlı model tahminleri tek katmanlı model tahminlerine göre daha başarılıdır. Bu iki haftalık test periyodu boyunca tek katmanlı model için NMAE % 16.85 iken çok katmanlı geliştirilen model için NMAE değeri % 12.63 olarak hesaplanmıştır.

Çizelge 3.2 Tek katmanlı model ile çok katmanlı geliştirilen modelin karşılaştırılması
(Gri gölgeli kısımlar karmaşık arazileri göstermektedir)

<i>Santral Numarası</i>	<i>Tek katmanlı Model NMAE (%)</i>	<i>Çok katmanlı Model NMAE (%)</i>
WPP1	12.89	11.30
WPP2	11.78	8.78
WPP3	16.90	11.75
WPP4	16.50	12.57
WPP5	13.10	11.52
WPP6	12.46	11.10
WPP7	12.26	10.34
WPP8	14.71	10.53
WPP9	12.16	9.36
WPP10	14.30	9.83
WPP11	13.69	12.53
WPP12	13.10	10.38
WPP13	16.06	11.54
WPP14	13.56	12.15
WPP15	13.44	9.55
WPP16	17.35	15.45
WPP17	13.57	10.20
WPP18	18.95	16.20
WPP19	18.27	16.39
WPP20	15.42	11.20
WPP21	12.16	9.95
WPP22	14.76	12.10
WPP23	18.15	16.74
WPP24	17.89	16.02
WPP25	15.25	12.85



Şekil 3.15 Örnek WPP için çok katmanlı ve tek katmanlı yapıların tahmin karşılaştırması (Tek katmanlı NMAE: %16.85, Çok katmanlı NMAE: % 12.63)

Bir diğer karşılaştırma yöntemi ise geliştirilen modelin fiziksel ve hibrit yöntemler içeren modellerle karşılaştırılmasıdır. Bu noktada, geliştirilen model tahminleri ile bilinen fiziksel model ve hibrit model [75] tahminlerinin tüm WPP'ler için karşılaştırma sonuçları Çizelge 3.3'te verilmiştir.

Sonuçları verilen fiziksel tahmin algoritması, hesaplamalı akışkanlar dinamiğini, WPP ve arazi karakteristiklerini (topoğrafya, türbin yerleşimleri, arazi pürüzlülüğü, engeller v.b.) kullanarak, istenilen arazi ve koordinatta türbin göbek yüksekliğinde rüzgârdan üretilen elektriksel güç tahmini yapmaktadır [75]. Bu yaklaşımda, fiziksel model referans tablolar oluşturabilmek için bütün olası rüzgâr hız ve yön değerleri ile koşturulur. Bu referans tablolar kullanılarak her bir WPP için NWP rüzgâr verileri, santral sahasına indirgenmiş yerel rüzgâr verilerine ve oradan da rüzgârdan-güce üretim tahminlerine dönüştürülür.


Sonuçta ise bir MOS yöntemi kullanılarak, tahmin ile gerçekleşen üretim arasındaki ilişki artırılır ve tahminler iyileştirilir. Çizelge 3.3'ten de görüldüğü gibi, geliştirilen çok katmanlı, basamaklandırılmış istatistiksel model NMAE değerleri, genellikle geleneksel fiziksel model tahminlerine göre daha iyi sonuç (WPP13 için % 4.6'ya kadar) vermektedir. Diğer taraftan hibrit model sonuçlarıyla karşılaştırınca, eğitim verisinin yaklaşık 24 ay olduğu WPP1'den WPP14'e kadar olan santrallerde % 1.9 NMAE değerine kadar daha iyi sonuç verdiği görülmektedir. Özellikle karmaşık arazili ve dağınık rüzgâr rejimli santraller için tahmin sonuçlarının daha başarılı olduğu görülmektedir. WPP15'den WPP25'e kadar olan santrallerde beklendiği gibi eğitim verisinin az olmasından dolayı hibrit modelden daha

Çizelge 3.3 Geleneksel tahmin yöntemleriyle önerilen modelin karşılaştırılması
(Gri gölgeli kısımlar karmaşık arazileri göstermektedir)

<i>Santral Numarası</i>	<i>Eğitim Periyodu (ay)</i>	<i>Fiziksel NMAE (%)</i>	<i>Hibrit NMAE (%)</i>	<i>Önerilen NMAE (%)</i>
WPP1	24	11.76	11.89	11.30
WPP2	24	9.54	9.27	8.78
WPP3	24	15.89	12.54	11.75
WPP4	24	12.07	13.46	12.57
WPP5	24	12.03	11.04	11.52
WPP6	24	12.79	11.62	11.10
WPP7	24	13.57	10.13	10.34
WPP8	24	14.75	12.43	10.53
WPP9	24	13.00	9.95	9.36
WPP10	24	14.15	11.35	9.83
WPP11	24	13.07	13.43	12.53
WPP12	24	11.63	11.32	10.38
WPP13	24	16.14	11.87	11.54
WPP14	24	12.50	12.31	12.15
WPP15	11	13.95	9.95	9.55
WPP16	8	14.40	12.63	15.45
WPP17	7	9.29	9.16	10.20
WPP18	8	12.13	14.10	16.20
WPP19	8	19.49	15.54	16.39
WPP20	7	12.36	8.54	11.20
WPP21	15	9.98	10.66	9.95
WPP22	5	13.37	11.83	12.10
WPP23	3	20.64	13.24	16.74
WPP24	3	15.45	16.15	16.02
WPP25	3	10.79	10.39	12.85

iyi belirgin bir fark gösterememiştir. Buradan anlaşılabilirdiği gibi geliştirilen tahmin modelinin kabul edilebilir iyi bir tahmin sonucu verebilmesi için eğitim verisinin en az 12 aylık büyüklükte olması gerekmektedir.

Tek katmanlı, fiziksel, hibrit ve istatistiksel tahmin modellerinin her biri için elde edilen hata dağılımları Şekil 3.16'da gösterilmiştir. Bu dağılım grafikleri, eğitim verisinin 12 aydan fazla olduğu ilk 14 santral tahminleri için verilmiştir. Burada görüldüğü gibi, 14 santral için NMAE cinsinden geliştirilen model % 10.98, hibrit model % 11.62, fiziksel model % 13.06 ve tek katmanlı model % 13.82 değerine ulaşmıştır.



Şekil 3.16 İlk 14 santral için tek katmanlı, fiziksel, hibrit ve önerilen modelin hata dağılımları
(Beş aylık test verisi kullanılarak elde edilmiştir)

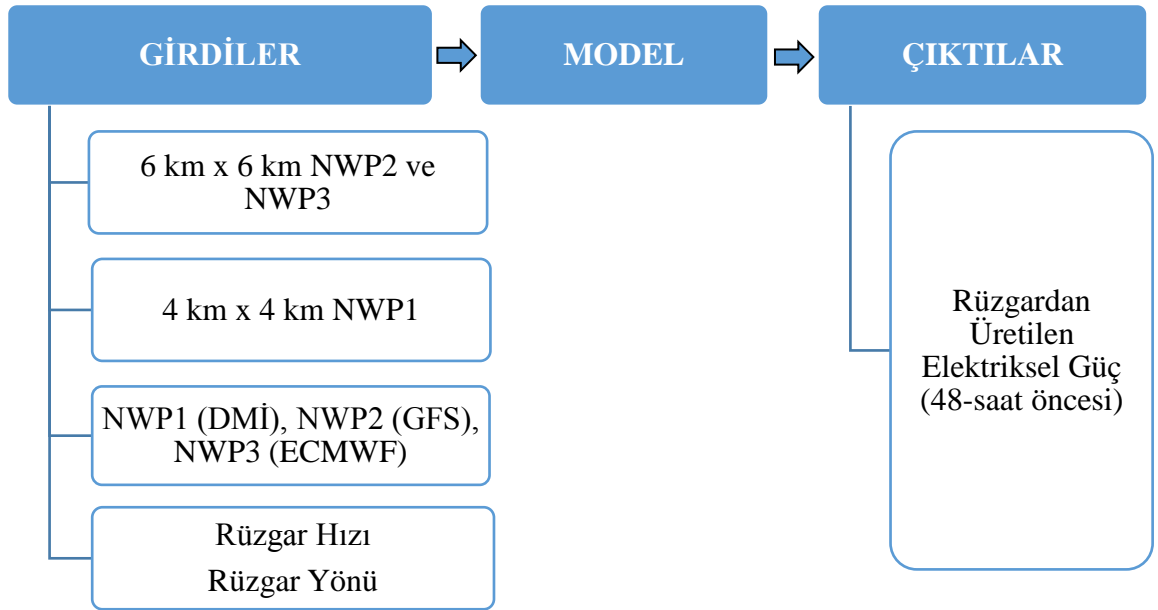
3.3.3. Veri İşleme

Geliştirilen modelde, 25 santralin her birinin tahmininde kullanılan tüm veriler bir sunucu bilgisayar üzerinde tutulmaktadır. Bu sunucu bilgisayar, 2.6 GHz frekansında 24 çekirdekli işlemci, 64 GB RAM ve 24 TB sabit disk özelliklerine sahiptir. DMİ'den elde edilen NWP verileri, tüm Türkiye için veri tabanı sunucularında toplamda 56126 meteorolojik grid verisi olarak veri tabanına kaydedilmektedir. Her bir santral için bu veriler önce en yakın 100 gride daha sonra modellerde kullanılmak üzere en yakın dokuz grid verisine indirgenerek analizler yapılmakta ve tahminler çıkarılmaktadır.

GFS ve ECMWF olarak kullanılan NWP verileri ise toplamda her bir santral için santral çevresini temsil eden 5400 grid noktasından 100 grid noktasına oradan da dokuz grid noktasına indirgenir. Her bir santral için tek bir grid içerisinde yaklaşık 2.1 MB boyutunda veri bulunurken 100 grid verisi analiz edilirken bu veri boyutu 210 MB olmaktadır. Tüm Türkiye için maksimum DMİ grid verisi dikkate alındığında sadece DMI NWP verileri için veri tabanında yaklaşık 117.8 GB boyutunda bir veri söz konusudur. GFS ve ECMWF NWP verileri ise her bir santral için 11.3 GB veri boyutlarına ulaşmaktadırlar.

Geliştirilen model, veri tabanı sunucuları üzerinde her bir santral için bir yıllık eğitim verisi için yaklaşık 210 saniye (3.5 dakika) hesaplama süresine ihtiyaç duymaktadır. Veri sayısı arttıkça hesaplama süresi de artmaktadır.

Geliştirilen modelin girdi/çıktıları Şekil 3.17’de verilmiştir. Girdilerde kullanılan NWP verileri NWP1 için 4 km x 4 km çözünürlüğe sahipken, NWP2 ve NWP3 için 6 km x 6 km çözünürlüğe sahiptir. NWP’lerden gelen veriler sıcaklık basınç ve nem gibi parametreleri de içerirse de bunlardan sadece rüzgâr hızı ve rüzgâr yönü verileri model girdisi olarak saatlik çözünürlükte kullanılmaktadır. Ayrıca girdi verisi içerisindeki hatalı değerler ön işlemlerle ayıklanmıştır. Model çıktısında ise her bir santral için rüzgârdan üretilen elektriksel gücün 48-saat öncesi tahminleri elde edilmektedir.



Şekil 3.17 Geliştirilen model için kullanılan girdiler/çıktılar

4. İYİLEŞTİRİLMİŞ RÜZGÂR-ELEKTRİK GÜÇ TAHMİNLERİ İÇİN RÜZGÂR ÖRÜNTÜSÜ TANIMA VE RÜZGÂR GÖZLEM İSTASYONU İLE NWP VERİ İLİŞKİSİ

Tez çalışmasının bu bölümünde her bir WPP için kısa-dönemli rüzgârdan üretilen elektriksel güç tahminlerinin iyileştirilmesi amacıyla, rüzgâr örüntüsü tanıma ve RWM ölçümleri kullanılarak NWP verisinin düzeltilmesi temellerine dayalı iki farklı yaklaşım sergilenmiştir. Literatürde rüzgârdan üretilen elektriksel güç tahminlerini iyileştirmek için bu iki yaklaşımı bir arada kullanarak istatistiksel tahmin modeli oluşturan herhangi bir çalışma bulunmamaktadır. Kullanılan model, bireysel grid hatalarını minimize etmek için öncelikle, birden fazla NWP grid verisini tek bir grid verisine dönüştürmek üzere Uyarlamalı Arttırma (AdaBoost) yöntemini kullanmaktadır. Daha sonra her bir NWP için elde edilmiş bu tek grid verisi sınıflandırılarak, her bir ANN ve SVM modeli öğrenme kapasitesi arttırılmaktadır. Buradaki sınıflandırma sayesinde rüzgârdan-rüzgâra aşamasının ilk kısmında, NWP verileri ile RWM ölçüm verileri arasındaki ilişki farklı ANN/SVM modelleriyle daha kolay ve yüksek doğrulukta öğrenilmiş olur. Çünkü, benzer özelliklere sahip rüzgâr bilgisi aynı sınıfta yer aldığından, bu sınıfa özel oluşturulmuş istatistiksel modellerin öğrenme kapasiteleri de arttırılmış olmaktadır. Daha sonra, rüzgârdan-rüzgâra aşamasının ikinci kısmında ise NWP ve RWM verileri arasındaki benzer zaman örüntüleri 48 saat önceki zaman çerçevesi içerisindeki periyodik davranışları dikkate alınarak özel bir yöntem sayesinde öğrenilir. Her bir WPP için, santral sahasına indirgenmiş ve düzeltilmiş rüzgâr verisi rüzgârdan-güce geçiş aşamasında yeni bir ANN/SVM kümesi kullanılarak ham 48-saat öncesi rüzgârdan üretilen elektriksel güç üretim tahminlerine dönüştürülmüş olur. Daha sonra sistematik hataların minimize edilmesi için MOS metodu kullanılmaktadır. MOS sonrası ham tahminlere, ağırlıklandırılmış ortalama kombinasyon metodu uygulanarak nihai kısa dönem rüzgârdan üretilen elektriksel güç tahminleri elde edilmektedir.

Geliştirilmiş bu tahmin modelinin literatüre olan önemli büyük katkıları şöyle özetlenebilir:

- Rüzgârdan üretilen elektriksel güç tahminlerinde dikkate değer bir iyileşme sağlamak için yeni bir örüntü tanıma tekniği temelinde istatistiksel tahmin modeli geliştirilmiştir. Model, rüzgârın zamansal periyodikliğini kullanarak geçmiş 24 ve 48 saat rüzgâr verisini dikkate almaktadır. Bu bilgiyi dikkate alarak NWP ve RWM

rüzgâr verisi örüntüleri arasındaki benzerlikleri belirler. Böylece NWP verisinden gelen hatalar RWM ölçümleri sayesinde minimize edilmiş olur.

- Yeni bir rüzgârdan rüzgâra düzeltme tekniği ile her bir WPP için, NWP verileri RWM ölçüm verilerine yaklaştırılarak santral sahasına indirgenir. NWP ile RWM verileri arasındaki korelasyona dayalı bu düzeltme sayesinde daha iyi sonuç veren rüzgârdan üretilen elektriksel güç tahminleri elde edilmiş olur.
- Geliştirilen bu yeni tahmin yapısı içerisinde sırasıyla, uyarlamalı yükseltme temelinde grid kombinasyonu, NWP veri sınıflandırması, RWM ölçümleri ile NWP veri düzeltme, rüzgâr örüntü tanıma bazlı öğrenme, ANN/SVM modelleri kullanarak rüzgârdan-rüzgâra geçiş ve rüzgârdan-güce geçiş, sistematik hata giderimi için MOS ve nihai bir tahmin üretmek için ağırlıklandırılmış ortalama kombinasyon yaklaşımı uygulanmaktadır.

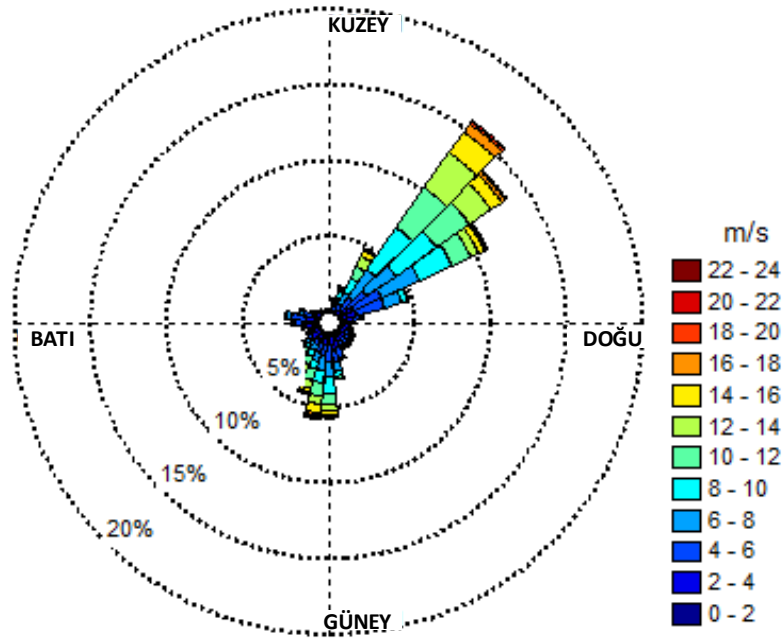
4.1. Geliştirilen Model

Tez çalışmasının bu bölümünde geliştirilen model iki yeni temel yaklaşıma dayanmaktadır. Birincisi, NWP verisini santral sahasına indirgeyebilmek için RWM verisi arasındaki ilişkiyi belirlemek, ikincisi ise santral sahasına indirgenmiş NWP verisi ile RWM verisi arasındaki benzer örüntüleri periyodik özellikten yararlanarak öğrenmektir. Bu iki temel yaklaşımın iyi tanımlanabilmesi ve uygun değerlendirilebilmesi neticesinde rüzgârdan üretilen elektriksel gücün tahmin edilmesinde önemli ölçüde iyileştirme sağlanmaktadır.

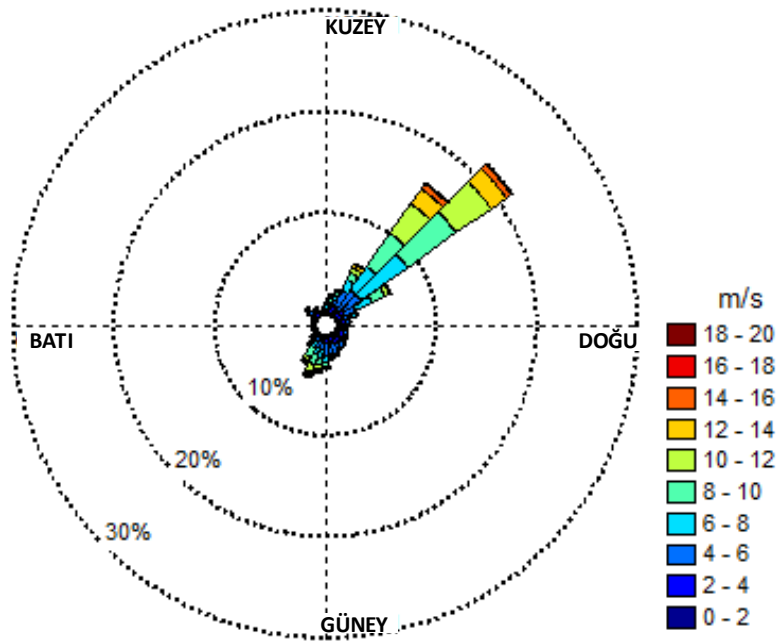
4.1.1. NWP ve RWM Verisi Arasındaki İlişki

NWP verisinin RWM ölçüm verileri kullanılarak santral sahasına indirgenmesi için aralarındaki korelasyonun bulunması önemlidir. Bu korelasyonun belirlenmesi amacıyla ilk olarak tüm WPP'lerin rüzgâr davranışlarının rüzgârgülleri sayesinde anlaşılması sağlanmıştır. Örnek bir WPP (WPP1') için Global Tahmin Sistemi (GFS) NWP verisi ile RWM ölçüm verisi kullanılarak elde edilen rüzgârgülü grafikleri Şekil 4.1'de verilmiştir. Tüm santraller için rüzgârgülü grafikleri Ek-5'te verilmiştir.

Şekil 4.1'den de anlaşıldığı gibi, RWM ölçümleri ile elde edilen rüzgârgülü, NWP ile elde edilen rüzgârgülüne oranla daha fazla saçılmış bir görünüme sahiptir. Bu durum WPP bölgesindeki rüzgâr davranışının gerçekte daha saçılmış rüzgâr hızı ve yönü değerlerine sahip bir yapıda olduğunu göstermektedir. Bu nedenle, elde edilmiş NWP verilerinin daha yüksek doğrulukta tahminler için, mümkün olduğunca düzeltilmesi ve RWM



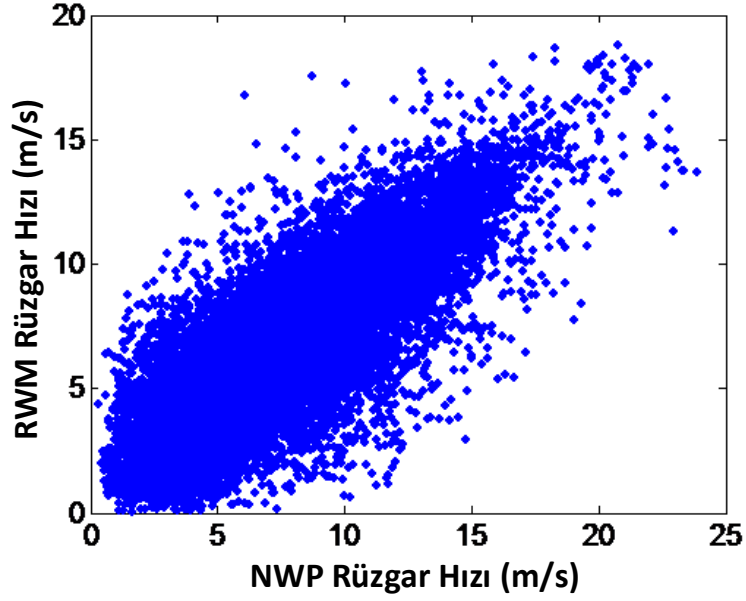
(a)



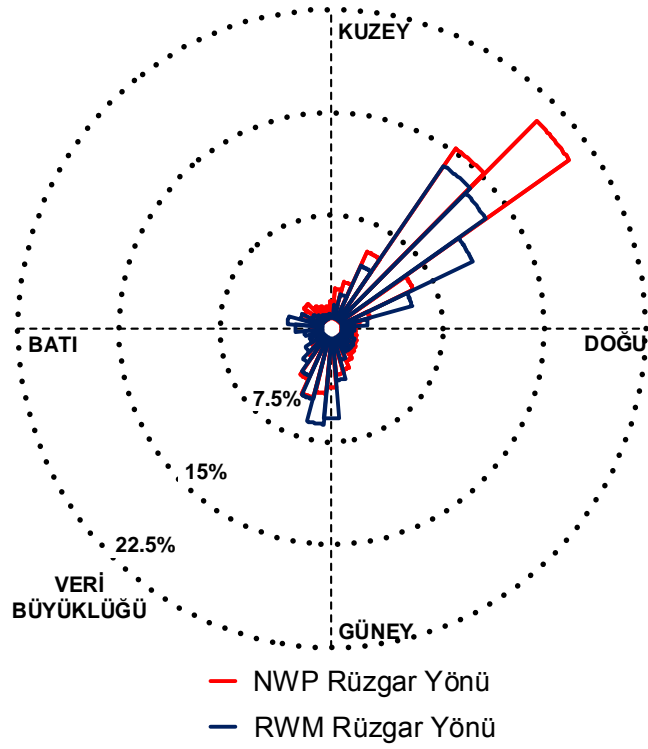
(b)

Şekil 4.1 Örnek bir WPP (WPP1') için rüzgârgülleri
(a) RWM rüzgârgülü, (b) NWP (GFS) rüzgârgülü

ölçümlerindeki yapıya benzetilmesi gerekliliği ortaya çıkmaktadır. Ek-5'te diğer tüm santraller için de hem RWM hem de NWP (GFS) rüzgârgülleri verilmiştir. Bu tespitin yanında NWP ve RWM için rüzgâr hızı verisi ve rüzgâr yönü verisi ile yeni analizler yapılmış, bu analizler sonucunda elde edilen saçılma grafikleri Şekil 4.2'de gösterilmiştir.



(a)



(b)

Şekil 4.2 Örnek bir WPP için NWP verileri ile RWM ölçüm verileri arasındaki korelasyon (a) RWM rüzgâr hızı verisi ile NWP rüzgâr hızı verisi, ve (b) NWP rüzgâr yönü verisi ile RWM rüzgâr yönü verisi

NWP rüzgâr hızı verisi ile RWM rüzgâr hızı verisi arasındaki korelasyon, Eşitlik (4.1)'de verildiği gibi Pearson doğrusal korelasyon metodu [82] ile bulunmuştur.

$$r = \frac{E[(X_{NWP} - E(X_{NWP}))(X_{RWM} - E(X_{RWM}))]}{\sqrt{V(X_{NWP})}\sqrt{V(X_{RWM})}} \quad (4.1)$$

burada, r korelasyon katsayısını, E beklenti değerini, V varyansı, X_{NWP} NWP veri vektörünü ve X_{RWM} veri vektörünü ifade etmektedir.

Diğer taraftan rüzgâr yönü verilerinin korelasyon değerleri ise Eşitlik (4.2)'de verildiği gibi dairesel korelasyon yöntemi [83] ile 360° aralık için elde edilmiştir.

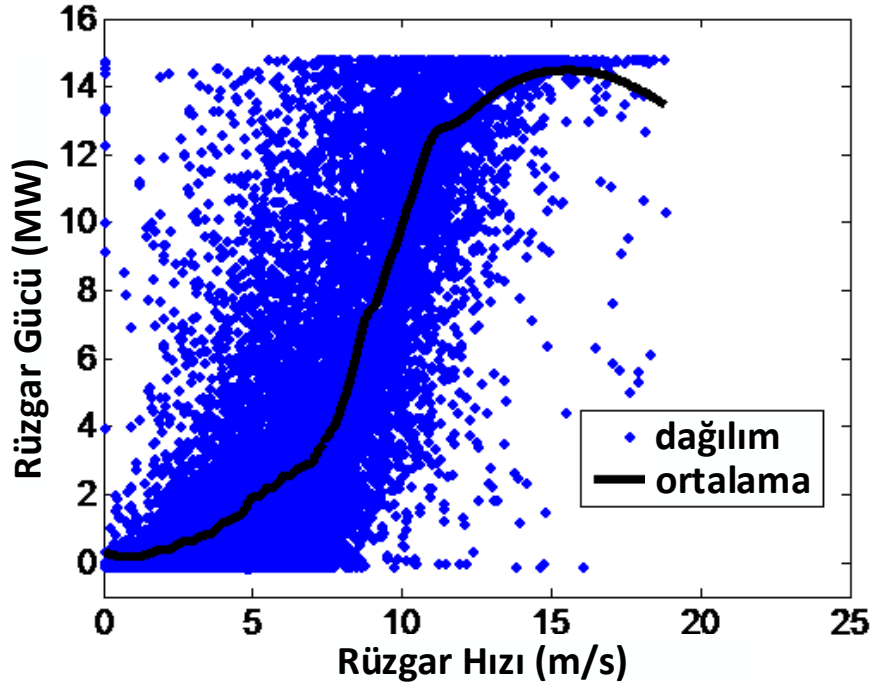
$$r_c = \frac{\sum_{i=1}^{n-1} \sum_{j=i+1}^n \sin(\alpha_i - \alpha_j) \sin(\beta_i - \beta_j)}{\sqrt{\sum_{i=1}^{n-1} \sum_{j=i+1}^n \sin^2(\alpha_i - \alpha_j) \sum_{i=1}^{n-1} \sum_{j=i+1}^n \sin^2(\beta_i - \beta_j)}} \quad (4.2)$$

burada, r_c dairesel korelasyon katsayısını, n veri sayısını, α ilk açısal değeri, β ise ikinci açısal değeri ifade etmektedir.

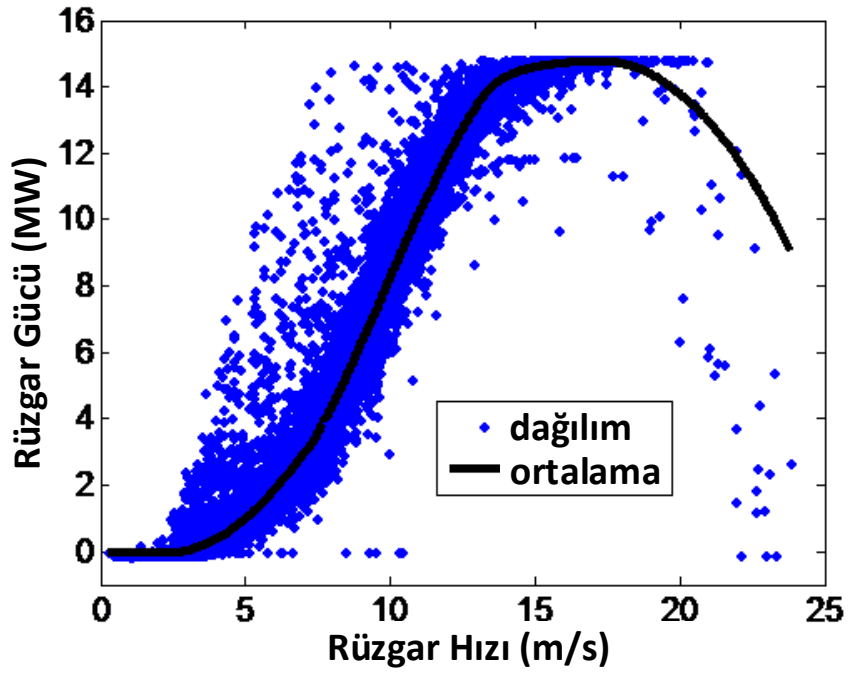
Örnek WPP analizinde rüzgâr hızı için 0.81, rüzgâr yönü için 0.72 gibi nispeten iyi bir korelasyon elde edilmiştir. NWP rüzgâr hızı verisinin korelasyon değeri NWP rüzgâr yönü verisine oranla daha yüksek değerlere ulaştığı görülmektedir.

Seçilen bir WPP için veri korelasyon grafikleri ile rüzgârgülü grafiklerinin elde edilmesinden sonra, rüzgârdan-güce geçiş ile bu veri kümesinin ne derece kaliteli olduğu anlaşılabilir. Bu bilgi Şekil 4.3'te verildiği gibi NWP ve RWM verileri kullanılarak elde edilen rüzgâr-güç eğrilerinden çıkartılmaktadır. Ortalama olarak çizilen çizgiler, lokal bir ağırlıklandırılmış yaklaşım ile dağılım grafiğini daha düz bir şekle getirmek için, her bir değer için komşu değerleri de kullanarak bulunmuştur. Saçılmış veriyi dikkate alan ikinci dereceden bir polinom fonksiyonu kullanılmıştır. Böylece fazla saçılmış verilere daha dirençli bir ortalama alma yöntemi uygulanmış olur.

Elde edilen grafiklerden görüldüğü gibi, NWP bazında rüzgâr-güç eğrileri daha fazla saçılmış karakteristiğe sahiptir (Şekil 4.3(a)). Bu şekilde yüksek oranda saçılmış güç değerlerinin olması rüzgârdan üretilen elektriksel gücün tahminlerinde yüksek hatayla karşılaşmaya neden olmaktadır. Ancak RWM ölçümleri ile çizilmiş rüzgâr-güç eğrisi ise daha az saçılmış bir karakteristiğe sahiptir (Şekil 4.3 (b)). Bu nedenle, NWP verileri ile RWM verileri arasındaki korelasyonun mümkün olduğunca iyi derecede tespit edilmesi, rüzgârdan üretilen elektriksel güç tahminlerinde daha başarılı sonuçların elde edilmesini sağlamaktadır. Tüm santrallere ait rüzgâr-güç eğrileri Ek-6'da verilmiştir.



(a)



(b)

Şekil 4.3 Örnek bir WPP (WPP1') için rüzgâr hızına göre rüzgârdan üretilen elektriksel güç değişimleri


(a) NWP (GFS) rüzgâr hızına karşılık WPP güç eğrisi (Normalize Ortalama Mutlak Hata, NMAE \cong % 14, 2 yıllık eğitim verisi için) (b) RWM rüzgâr hızına karşılık WPP güç eğrisi (NMAE \cong % 4, 2 yıllık eğitim verisi için)

4.1.2. Rüzgâr Örüntüleri


Örüntü bazında öğrenme yaklaşımı, NWP rüzgâr verilerindeki tekrarlayan örüntülerin RWM ölçümlerindeki tekrarlayan örüntülere çok benzer davranışlar göstermesinden gelmiştir. Bu durumu ifade eden örnek bir WPP için örnek bir zaman penceresinde çizilmiş grafik Şekil 4.4’te verilmiştir. Benzer rüzgâr hızı örüntüleri, büyüklük ve örüntü şekilleri dikkate alınarak farklı sınıflara ayrılmaktadır. Bu durumu özetleyen bazı tipik rüzgâr hızı örüntüleri Şekil 4.4’te örnek bir santral için elips ve dikdörtgen çerçeveler içerisinde iki farklı sınıfı temsil edecek şekilde verilmiştir.

Rüzgâr verileri içerisindeki benzer özelliklere sahip örüntülerin uygun olarak sınıflandırılması, daha iyi bir öğrenme aşamasıyla beraber daha az hata sonucu veren rüzgârdan üretilen elektriksel güç tahminlerinin yapılmasını sağlar. Bu sınıfların detaylı olarak incelenmesiyle, NWP ve RWM verileri arasındaki örüntülerde genel bir periyodiklik olduğu ortaya çıkmıştır. Bu periyodik özelliklerin tahmin modeline entegre edilmesi, iyileştirilmiş tahminlere ulaştırmaktadır. Prensip olarak NWP ve RWM rüzgâr hızı veri örüntüleri arasındaki ilişki geçmiş veri çerçeveleri ile belirlenmektedir.

Rüzgâr örüntüleri incelenirken NWP verileri ile RWM ölçüm verileri arasında Şekil 4.4’de görüldüğü gibi RWM ölçümlerinin NWP verilerden sürekli daha yüksek değerlere sahip değildir.



Şekil 4.4 NWP ve RWM verileri ile elde edilmiş tipik örüntü örneklerinin elips ve dikdörtgen çerçevelerle gösterilmesi



Şekil 4.5 Üç NWP rüzgâr hızına karşılık RWM rüzgâr hızı verisi

Üç NWP verisi ile RWM ölçümlerinin değişimleri örnek bir zaman aralığı için Şekil 4.5'te verilmiştir. NWP verileri, modelin doğruluğuna ve sistematik hatalarına bağlı olarak RWM değerlerinden düşük değerlere de, yüksek değerlere de sahip olabilmektedir. Bu durum farklı zaman pencerelerinde, gün, saat ve mevsimsellik gibi durumlara bağlı olarak değişmektedir.

4.2. Geliştirilmiş Rüzgârdan Üretilen Elektriksel Güç Tahmin Modeli

Geliştirilen rüzgâr örüntü tanıma ve RWM korelasyon temeline dayanan rüzgârdan üretilen elektriksel güç tahmin modeli için altı basamaklı genel blok şema Şekil 4.6'da verilmiştir. Öncelikle uygun olan üç NWP verisi ile her bir santrale en yakın dokuz grid verisi özel bir grid kombinasyon metodu ile kombine edilir. Daha sonra RWM temelinde bir korelasyon metodu ile rüzgâr örüntü tanıma bazlı bir yöntem uygulanır. Bu aşamadan sonra istatistiksel ara modeller kullanarak rüzgârdan-rüzgâra geçiş yapılır. Düzeltilmiş rüzgâr verileri olarak adlandırılan bu rüzgâr verileri ara istatistiksel modeller kullanılarak güce dönüştürülür. Tahmin edilen rüzgârdan üretilen elektriksel güç verilerindeki sistematik hata giderimi için MOS uygulanır. Son aşamada ise düzeltilmiş ara güç üretim tahminleri, kombinasyon ile nihai rüzgârdan üretilen elektriksel güç tahminlerine dönüştürülür. Geliştirilen modelin eğitim ve test aşamalarında basamak basamak uygulama yöntemleri Şekil 4.7'de verilmiştir.

4.2.1. AdaBoost Grid Kombinasyonu ve K-means NWP Veri Sınıflandırması

Geliştirilen modelde, ilk olarak En küçük kareler (LS) AdaBoost yöntemi kullanılarak her bir WPP için en yakın dokuz grid verisi güçlü nihai bir grid verisine dönüştürülür. Elde edilen rüzgâr verilerini içeren bu grid kombinasyonu sonucunda santralin genelini en iyi temsil eden meteorolojik grid verisi oluşturulur.

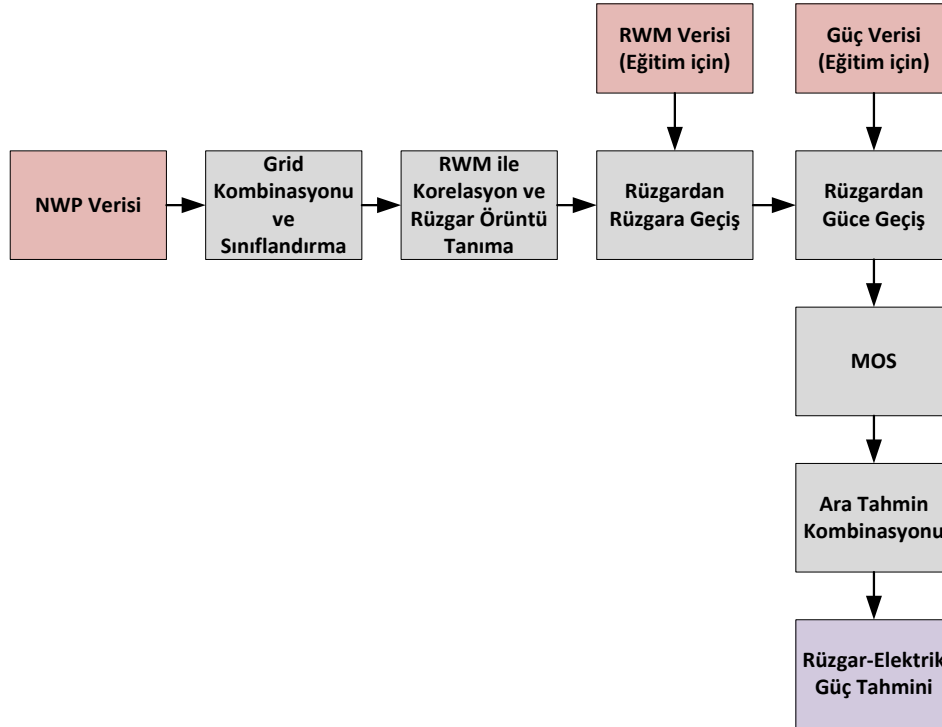
AdaBoost ile elde edilen grid verisi her bir NWP için K-means metodu ile sınıflandırmaya tabi tutulur. K-means sınıflandırma metodu, gözlem değerlerini çıkışta k tane sınıf oluşturacak şekilde sınıflandırır [84].

NWP verisinin sınıflandırılması, RWM verisi ile arasındaki korelasyonun daha başarılı bir şekilde bulunmasını sağlamaktadır. Ayrıca örüntü tanıma bazlı öğrenmelerde kullanılan örüntüler aynı sınıfa düşürülmüş olur. Bu noktada belirlenen sınıf sayısı, farklı alternatif sınıf sayıları denenerek en iyi sonucu veren sınıf sayısı NWP bazlı olarak belirlenir.


Hem Adaboost yaklaşımı hem de K-means sınıflandırma yaklaşımı Ek-2’de detaylı olarak anlatılmıştır.

4.2.2. İstatistiksel Metotlar: ANN ve SVM

Geliştirilen modelde hem rüzgârdan-rüzgâra geçişte hem de rüzgârdan-güce geçişte istatistiksel metotlar olan ANN ve SVM metotları kullanılır. İyi bir rüzgârdan üretilen



Şekil 4.6 Geliştirilen model için genelleştirilmiş blok şema



Şekil 4.7 RWM düzeltme ve rüzgâr örüntü tabanlı önerilen yöntemin eğitim ve test sistemi; (Kayıt eğitim aşamasında kullanılır, Çağırma test aşamasında kullanılır); W-to-W: rüzgârdan rüzgâra geçiş ve W-to-P: rüzgârdan güce geçiş

elektriksel güç üretim tahmin modeli için ANN ve SVM modellerinin yapı ve parametreleri uygun seçilmelidir. ANN birçok yapay nöron ve bu nöronları birbirine bağlayan ağırlıklandırılmış bağlantılardan oluşur [49]. Katmanlar arasındaki veri iletişimi bu bağlantılar sayesinde gerçekleşerek nöron çıkış değerleri ile sonraki katmanlara taşınır. Çok katmanlı bir ANN yapısı özellikle rüzgârdan üretilen elektriksel güç üretim tahmini gibi doğrusal olmayan problemlerin çözümünde oldukça başarılı sonuçlar vermektedir. Bu problemler için kullanılan çok katmanlı algılayıcı (MLP) yapısındaki ANN modeli, girdi katmanı, çıktı katmanı ve bir ya da daha fazla sayıda gizli katmandan oluşmaktadır. Her bir katmandaki bir ya da daha fazla sayıda nöron önceki ve sonraki katmanlara direkt olarak bağlıdır. Girdi değerleri ağırlık değerleri ile çarpılarak gizli katman nöronundan sonra

aktivasyon fonksiyonundan geçirilir. Rüzgâr karakteristiğine uygun olarak geliştirilen tahmin modeli için sigmoid aktivasyon fonksiyonu kullanılmıştır. Her bir gizli katman nöronunda çıkış değerini elde edebilmek için ağırlıklandırılmış girdiler toplanarak aktivasyon fonksiyonundan geçirilir. Böylece gizli katman sonrasında gelen ağırlıklandırılmış girdiler, aktivasyon fonksiyonunu ile çıktı değerleri elde edilir.

Geliştirilen modelde, tek gizli katmana sahip üç katmanlı ileri beslemeli bir ANN yapısı kullanılmıştır. Hem gizli katmanda hem de çıkış katmanında aktivasyon fonksiyonu olarak sigmoid aktivasyon fonksiyonu kullanılmıştır. Çok sayıda kombinasyon denenerek en iyi tahmin sonucunu veren nöron sayıları bulunmuştur. Rüzgârdan-rüzgâra geçişte, girdi katmanında iki nöron, gizli katmanda ise santral bazlı olarak 3-20 aralığında değişen sayıda nöron ile çıkış katmanında bir nöron kullanılmıştır. Yine benzer şekilde rüzgârdan-güce geçiş aşamasında, iki adet girdi katman nöronu, 5-45 aralığında gizli katman nöronu ile çıkış katmanında bir nöron kullanılmıştır. Modellerin eğitim aşamasında, toplu veri esnek geri besleme algoritması kullanılarak MSE değerlerini minimize ederek ANN model parametreleri bulunmuştur. MSE hesaplaması Eşitlik (4.3)'te verilmiştir.

$$MSE = \frac{1}{L} \sum_{u=1}^L (P_u - R_u) \quad (4.3)$$

burada, L örnek sayısını, P_u u'nuncu tahmini, R_u u'nuncu gözlem değerini ifade etmektedir.

SVM modeli ise, regresyon problemlerine başarılı bir şekilde uygulanabilen, hem doğrusal hem de doğrusal olmayan yapıya sahip olan bir makine öğrenme metodudur. Rüzgâr üretim tahminlerinin doğrusal olmayan yapısı nedeniyle SVM tahmin modelleri doğrusal olmayan yapısı ile bu problemlere uygulanmıştır.

Geliştirilen tahmin modelinde RBF kernel fonksiyonu kullanan SVM modeli regresyon yapısı hem rüzgârdan-rüzgâra ve rüzgârdan-güce tahminlerde kullanılan model olarak belirlenmiştir. SVM modeli kernel parametreleri, eğitim aşamasında en düşük MSE değerlerine ulaştıran iterasyonlarla bulunur. Bulunan bu optimum SVM parametreleri test aşamasında kullanılmak üzere kaydedilir.

4.2.3. MOS ve Kombinasyonlar

Rüzgârdan-güce geçiş aşamasından sonra ara tahminlerdeki sistematik hatanın minimize edilmesi MOS ile yapılır. MOS parametreleri eğitim aşamasında belirlenerek test aşamasında ham 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri bu parametreler kullanılarak düzeltilir.

Geliştirilen modelin son aşaması ara tahminlerin kombine edildiği ve nihai tahminlere dönüştürüldüğü aşamadır. Her bir NWP modeli için üç ANN modeli ve üç SVM modeli ara tahminleri olmak üzere toplam altı ham ara tahmin, ağırlıklandırılmış ortalama kombinasyon yaklaşımı ile nihai tahminlere dönüştürülür. Bu yöntem Eşitlik (4.4)'te verilmiştir.

$$WA = \frac{w_1y_1 + w_2y_2 + \dots + w_my_m}{w_1 + w_2 + \dots + w_m} \quad (4.4)$$

Burada, WA ağırlıklandırılmış ortalama tahmini, w_1 'den w_m 'e kadarki değerler her bir ara tahmin için bulunan ağırlık değerlerini ve y ise ara tahminleri ifade etmektedir. Kombinasyon sonucunda nihai 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri elde edilmiş olur.

4.3. Yöntemin Uygulanması

Geliştirilen modelde kullanılan NWP verileri, farklı orta ölçekli hava tahmin modellerinden alınmıştır. Her bir WPP için meteorolojik veri alınarak sırasıyla 6 km x 6 km ve 4 km x 4 km çözünürlüklere WRF (The Weather Research and Forecasting) ve ALADIN (Aire Limitée Adaptation dynamique Développement International) modelleri ile çevrilir. Elde edilen hava tahmin verileri saatlik çözünürlükte rüzgâr hızı ve yönü bilgilerini içermektedir. Bu modeller için detaylı açıklamalar Ek-3'te verilmiştir.

Modelin uygulanması, eğitim ve test olmak üzere iki ardışık aşamadan geçilerek yapılmaktadır. Eğitim aşaması, Şekil 4.7'de verildiği gibi doğrusal olmayan modellerin tasarlanması, parametrelerinin belirlenmesi ve bu parametrelerin kaydedilmesi temeline dayanır. Diğer taraftan test aşaması ise kaydedilmiş parametrelerin çağrılarak nihai rüzgârdan üretilen elektriksel güç üretim tahminlerinin yapılması temeline dayanır.

4.3.1. WPP ve RWM Kurulumları

RİTM projesi kapsamında Türkiye geneline yayılmış yedi santral için RWM'ler kurulmuştur [85]. RWM kurulmuş tüm WPP'lere ait bazı teknik özellikler ve ilgili RWM'lere ait teknik detaylar Çizelge 4.1'de verilmiştir. Çizelge 3.1'de verilmiş olan WPP numaralarından bazıları bu kısımda farklı numaralar ile ifade edilmiştir. NWP'lerin içine ya da yakınlarına kurulmuş RWM'lerden her biri, altı anemometre, iki rüzgâr çanağı, iki sıcaklık ve nem sensörü ve bir basınç sensörü taşır. Yine her bir RWM üzerinde veri toplama periyodu bir saniye olan GPRS (General Packet Radio Service) haberleşmeli bir

adet veri kaydedici bulunmaktadır. WPP'ye kurulmuş tipik bir RWM için örnek resimler Şekil 4.8'de verilmiştir.

Geliştirilen tahmin modelinde kullanılan güç üretim verileri ise, WPP'nin elektrik hattına bağlanmış Rüzgâr Enerji Analizörleri sayesinde elde edilmektedir [77]. Güç verileri eğitim aşamasında model parametrelerini belirlemede vazgeçilmez önemdedir. Her bir WPP için trafo merkezine bağlanmış olan bu analizörler ile IEC-61000-4-30 standardına uygun olarak, kanal başına 25.6 kHz örnekleme hızında gerilim, akım, güç, frekans ve harmonik gibi güç kalitesi parametrelerinin ölçümleri yapılmaktadır. Zaman senkronizasyonu GPS (Global Positioning System) ile gerçekleştirilerek aynı anda elektrik hattı üzerindeki gerilim çukuru, gerilim tepesi ve gerilim kesintisi olaylarının kayıtları yapılmaktadır.

Çizelge 4.1 WPP'ler ve RWM'lerin bazı teknik özellikleri

SANTRAL	Çizelge 3.1'deki Santral Numarası	Rüzgâr Türbin Sayısı	Kurulu Güç (MW)	RWM Anemometre Yüksekliği (m)	RWM Rüzgâr Çanak Yüksekliği (m)
WPP1'	WPP1	5	15	50, 65, 80	48, 78
WPP2'	WPP2	36	90	50, 65, 80	48, 78
WPP3'	WPP3	20	86.4	50, 65, 80	48, 78
WPP4'	WPP5	17	10.2	30, 45	28, 43
WPP5'	WPP8	54	135	50, 65, 80	48, 78
WPP6'	WPP9	98	196.1	30, 50, 65	28, 63
WPP7'	WPP10	16	48	50, 65, 80	48, 78



Şekil 4.8 RWM görünümüleri soldaki: kurulum, sağdaki: yandan görünüş

4.3.2. Eğitim Aşaması


Saatlik çözünürlükte yaklaşık iki yıllık veri kullanılarak eğitim aşasında, parametreler belirlenerek modeller eğitilir. Elde edilen parametreler test aşamasında kullanılmak üzere kaydedilir. Eğitim aşamasının ilk kademesi olan AdaBoost grid kombinasyon yöntemi ile en yakın dokuz grid verisi kombine edilerek her bir NWP için rüzgâr hızı ve yönü verisi içeren tek bir grid verisi elde edilmektedir. Bu aşamada bulunan AdaBoost parametreleri veri tabanına kaydedilir. Bir sonraki adımda, her bir NWP ve WPP için rüzgâr hızı ve yönü bilgilerini içeren kombine grid verisi K-means metodu ile belirlenen optimum sayıdaki sınıflara ayrılır. Hem sınıfların merkez değerleri hem de optimum sınıf sayıları veri tabanına kaydedilir.

Sınıflandırılmış veriler rüzgârdan-rüzgâra geçiş aşaması içerisinde öncelikle NWP ve RWM verileri arasındaki korelasyonu daha başarılı bir şekilde belirlemede kullanılır. Korelasyon ile düzeltilen NWP verileri örüntü tanıma adımında kullanılmak üzere hazırlanır. NWP verileri ile RWM ölçüm verileri örüntüleri kullanılarak geçmiş 24 ve 48 saatlik zaman periyotları boyunca örüntüler arasındaki benzerlik ortaya çıkarılır. Geliştirilen bu yöntem ile t anında rüzgâr hızı değeri Eşitlik (4.5)'te verildiği gibi bulunur.

$$Rs(t) = f\{Ns(t, (t - 24), (t - 48)), Rs((t - 24), (t - 48))\} \quad (4.5)$$

burada, $Rs(t)$ t anındaki RWM rüzgâr hızını, f , ANN/SVM model yapılarıyla oluşturulmuş örüntü tanıma bazlı fonksiyonu ve Ns NWP rüzgâr hızını ifade etmektedir. RWM rüzgâr hızının t anındaki tahmin değeri bulunurken, NWP rüzgâr hızı örüntüsünün t , $t-24$ ve $t-48$ anındaki değerleri ile RWM rüzgâr hızı örüntüsünün $t-24$ ve $t-48$ anındaki değerleri birlikte kullanılır. Bu yaklaşım Şekil 4.9'da daha açık ifade edilmiştir. Saatlik çözünürlükteki her adımda bu işlem tekrarlanır. Ayrıca, rüzgâr yönü verileri için de aynı yaklaşım sergilenerek örüntüler arasındaki ilişki ortaya çıkarılmış olur. Bu rüzgârdan-rüzgâra geçiş aşaması ile düzeltilmiş NWP verileri elde edilir parametreler veri tabanına kaydedilir.

Düzeltilmiş rüzgâr verisi bir sonraki aşamada rüzgârdan-güce geçiş için kullanılır. Bu aşamada yeni ANN/SVM modelleri, düzeltilmiş rüzgâr verisinin yanında rüzgâr enerjisi analizörleri ile ölçülen güç üretim verilerini de kullanarak eğitilir. Bu işlem her NWP için WPP bazlı olarak yapılır. Elde edilen tüm model parametreleri veri tabanına kaydedilir. Güce geçiş ile ham ara 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminleri yapılmış olur. Tahminler üzerindeki sistematik hatalar MOS metodu ile giderilir. Bu metot



Şekil 4.9 NWP verisi ve RWM verisi örüntüleri kullanılarak $R_s(t)$ rüzgâr hızı tahmini yapılması

İçin eğitim verisi üç eşit parçaya bölünerek iki parçası MOS parametrelerinin belirlendiği MOS eğitim aşaması için kullanılır. Kalan üçte birlik veri ise belirlenen parametrelerin doğrulanmasında kullanılarak geliştirilen modelin test aşamasında kullanılan nihai MOS parametrelerini bulmada kullanılır. Tüm bu parametreler veri tabanına kaydedilir.

Son aşamada ise, sistematik hataları giderilmiş ham 48 saat öncesi elektriksel güç üretim tahminleri, ağırlıklandırılmış ortalama metodu ile kombine edilerek nihai tahminler bulunur. Eğitim aşamasında, MOS doğrulama aşamasına benzer şekilde, eğitim verisi üç eşit parçaya bölünür. Bunlardan iki parçası kombinasyon yapısını ve parametrelerini belirlemede kullanılırken, üçüncü parçası oluşturulan kombinasyon yapısını doğrulamada kullanılır. Kombinasyon modeline ait ağırlık değerleri test aşamasında kullanılmak üzere veri tabanına kaydedilir.

4.3.3. Test Aşaması

Eğitim aşamasında kaydedilen tüm parametreler test aşamasında kullanılarak nihai tahminler yapılır. Test aşamasında tahminlerde dikkate değer iyileşme sağlamak için 6 aylık veri kullanılır. Öncelikle, her bir NWP için test verisi içerisindeki WPP'ye en yakın dokuz grid verisi eğitim aşamasındaki AdaBoost (Ek-2) yapısı ile kombine edilerek rüzgâr hızı ve yönü değerlerini içeren tek bir test gridi elde edilir. Bu test grid verisi eğitim aşamasında merkez değerleri belirlenmiş K-means yapısı ile uygun sayıda sınıfa ayrılarak rüzgârdan-rüzgâra geçiş aşamasına gönderilir. Bu aşamada öncelikle NWP verisi ile RWM verisi arasındaki korelasyon düzeltmesini yapan ANN/SVM model yapıları veri tabanından çekilerek kullanılır. Daha sonra örüntü tanıma metodu için parametre ve ANN/SVM modellerini içeren yapılar kullanılarak düzeltilmiş NWP rüzgâr verilerine ulaşılır. Hem korelasyon düzeltmesi hem de örüntü tanıma ile yapılan düzeltmeler eğitim aşamasında

kullanılan adımlara benzer şekilde uygulanır. Rüzgârdan-güce geçiş aşamasına gelen düzeltilmiş NWP verileri, eğitim aşamasında elde edilmiş yeni ANN/SVM model setleri ile ham güç tahminlerine dönüştürülür. Sistemik hatalar kayıtlı MOS parametreleri ile minimize edilerek kombinasyon aşamasına hazır hale getirilir. Son adımda ise eğitim aşamasında kaydedilmiş ağırlık değerleri kullanılarak, nihai rüzgârdan üretilen elektriksel güç üretim tahminleri oluşturulur.

4.4. Önerilen Modelin Sonuçları

Geliştirilen modelin performansı, hem rüzgârdan rüzgâra geçiş aşamasında hem de rüzgârdan güce geçiş aşamasında ayrı ayrı değerlendirilmiştir. Rüzgârdan rüzgâra geçiş aşamasında NWP verisinin model ile düzeltildikten sonraki sonuçları incelenirken, rüzgârdan güce geçişten sonraki model sonuçları geleneksel istatistiksel modeller ve hibrit bir ticari sistem sonuçları ile de karşılaştırılmıştır.

4.4.1.NWP Verisi ile RWM Verisi Karşılaştırması

Her bir WPP için santral sahasındaki rüzgâr karakteristiğini en iyi temsil eden koordinatlara bir adet RWM kurulmuştur. NWP verileri ile RWM ölçüm verileri arasındaki ilişkiyi belirlemek özellikle tahminlerde yapılabilecek iyileştirmeler hakkında ön bilgi vermektedir. Bu nedenle tüm WPP'lerde NWP ve RWM rüzgâr hızı verileri için doğrusal korelasyon katsayısı hesaplanmıştır. Benzer şekilde NWP rüzgâr yönü ile RWM rüzgâr yönü verileri arasındaki ilişkiyi belirlemek için dairesel korelasyon katsayıları bulunarak Çizelge 4.2'de gösterilmiştir. WPP'lerin çoğunda NWP verisi ile RWM verisi arasında iyi bir korelasyon olduğu görülmektedir.

Yeterli miktarda RWM verisi kullanılarak, eğitim aşamasıyla birlikte test aşamasında da RWM verisinin elde olduğu varsayılarak tahminler yapılmıştır. Temel bir karşılaştırma testi için ilk olarak, sadece NWP verisi kullanılarak tahminler yapılmış, ikinci olarak ise sadece RWM verisi kullanılarak tahminler yapılmıştır. Bu testler sırasında tüm santraller için temel düzeyde ANN/SVM yapısı oluşturularak, 12-18 ay arasında değişen eğitim verisi ile 6 aylık test verisi kullanılmıştır. Elde edilen tahmin sonuçları Çizelge 4.3'te verilmiştir.

NMAE hata oranlarına bakıldığında, NWP tabanlı tahminlerin hata oranları % 10-16 arasında değişirken, RWM tabanlı tahminlerin hata oranları % 4-8 aralığında değiştiği görülmektedir. Bu sonuçlar RWM ile yapılan tahminlerin % 30-72 aralığında NWP tahminleri üzerinde düzeltme getirdiğini göstermektedir. Bu sonuçlar, NWP verisi ile

Çizelge 4.2 RWM ile NWP verileri arasındaki doğrusal ve dairesel korelasyonlar

Santral	Rüzgâr Hızı Doğrusal Korelasyon Katsayısı	Rüzgâr Yönü Dairesel Korelasyon Katsayısı
WPP1'	0.81	0.72
WPP2'	0.81	0.72
WPP3'	0.72	0.67
WPP4'	0.77	0.75
WPP5'	0.60	0.52
WPP6'	0.76	0.78
WPP7'	0.81	0.80

Çizelge 4.3 Temel Test Sonuçları: Sadece NWP verisi ya da sadece RWM ölçümleri ile elde edilen NMAE hata oranları


SANTRAL	NWP1 NMAE (%)	NWP2 NMAE (%)	NWP3 NMAE (%)	RWM NMAE (%)
WPP1'	14.32	14.16	13.65	3.81
WPP2'	12.47	13.20	10.18	5.13
WPP3'	15.78	15.95	15.44	5.71
WPP4'	14.85	15.58	12.08	5.62
WPP5'	11.73	12.11	12.85	8.25
WPP6'	12.46	12.33	11.43	6.05
WPP7'	15.81	12.44	11.68	5.50

RWM verisi arasındaki ilişkiyi belirleyerek tahmin yapısına entegre etmenin daha başarılı tahmin sonuçları vereceğini ortaya koymaktadır.

4.4.2. Geliştirilen Model ile Süreklilik Modeli Karşılaştırması

Temel bir kıyaslama modeli olan ve literatürde tahmin sistemlerinin performanslarının test edilmesinde sıklıkla kullanılan süreklilik modeli sonuçları ile geliştirilen model tahmin sonuçları karşılaştırılmıştır. Bu sonuçlar yedi santral için de bar grafikleri şeklinde Şekil 4.10'da verilmiştir. Görüldüğü gibi geliştirilen model süreklilik modeli tahminlerine göre WPP bazlı olarak % 25 ile % 71 aralığında değişen oranlarda iyileştirme getirmektedir.


Çizelge 4.2'de görüldüğü gibi NWP ve RWM arasında en düşük korelasyona sahip WPP5' santrali için beklendiği gibi en düşük iyileştirme değeri elde edilmiştir. Diğer taraftan en




Şekil 4.10 Süreklilik metodu ile önerilen metodun karşılaştırılması

yüksek korelasyon katsayılarına sahip WPP1' ve WPP2' için en yüksek iyileştirme değerleri elde edilmiştir.

Tüm yedi santral için, hem süreklilik metodu (persistans metodu) hem de geliştirilen model için normalize edilmiş güç tahmin hata dağılımları Şekil 4.11'de verilmiştir. Süreklilik modeli hata ortalama değeri 0.25 iken geliştirilen model için bu değer 0.28'dir. Ortalama değerlerin yaklaşık olarak yakın çıkmalarına rağmen, standart sapma değerleri tahmin doğrulukları hakkında asıl bilgiyi verecek değişkendir. Süreklilik modeli standart sapma değeri 31.21 bulunurken bu değer geliştirilen model için 8.97'dir. Daha düşük standart sapma daha dar yapıda bir hata dağılım grafiğini göstermektedir. Daha dar hata dağılımı da geliştirilen modelin süreklilik modelinden daha güçlü bir tahmin modeli olduğunu göstermektedir.



(a)



(b)

Şekil 4.11. Süreklilik metodu ile önerilen metot hata dağılımları
(a) Süreklilik metodu (b) Önerilen metot

4.4.3. Önerilen Modelin Diğer İstatistiksel Modellerle Karşılaştırılması


Geliştirilen modelde ilk olarak NWP verileri RWM verileri ile düzeltilir. Bu düzeltme daha doğru rüzgâr hızı ve rüzgâr yönü değerleri elde etmeyi sağlamaktadır. Düzeltilmiş rüzgâr verileri ile yapılan güç tahminleri daha iyi sonuç vermektedir. Tüm santraller için RWM kullanılarak yapılan düzeltmeler ile RWM düzeltmesi yapılmadan var olan NWP rüzgâr tahminleri için elde edilen MAE değerleri Çizelge 4.4’te verilmiştir. RWM düzeltmesi ile elde edilen sonuçların düzeltme olmadan elde edilen sonuçlara göre daha iyi olduğu görülmektedir.

Elde edilen düzeltilmiş rüzgâr tahmin değerleri hem RWM ölçümleri ile hem de ham NWP ölçümleri ile karşılaştırılmıştır. Bu karşılaştırma için her bir rüzgâr hızı veri seti için Weibull dağılımı Şekil 4.12’de verilmiştir. Görüldüğü gibi yayılmış bir dağılıma sahip olan ham NWP rüzgâr hızı tahminleri, rüzgârdan rüzgâra aşamasında RWM veri korelasyonu ve rüzgâr örüntü tanıma tabanlı yaklaşımlarla düzeltilmiştir. Şekil 4.12’den de görüldüğü gibi düzeltilmiş NWP rüzgâr hızı tahminleri RWM rüzgâr hızı ölçümlerine daha fazla yakınsamıştır. İlgili rüzgâr hızı ortalama değerleriyle ilişkili olan Weibull dağılımı ölçek parametreleri, sırasıyla ham NWP için 10.14, RWM ölçümleri için 6.56 ve düzeltilmiş NWP için 6.51 değerleri bulunmuştur.

Diğer taraftan, rüzgâr hızı dağılımı ile ilişkili olan biçim parametresi ise sırasıyla ham NWP için 3.49, RWM ölçümleri için 2.77 ve düzeltilmiş NWP için 4.38 olarak hesaplanmıştır.

Çizelge 4.4 Rüzgârdan rüzgâra hız ve yön hataları ile NWP hız ve yön hata karşılaştırması

Santral	Rüzgâr Hızı için MAE (m/s)		Rüzgâr Yönü için MAE (°)	
	NWP	NWP’den RWM’e	NWP	NWP’den RWM’e
WPP1’	2.09	1.73	44.65	38.82
WPP2’	2.37	1.90	42.07	41.06
WPP3’	2.46	1.94	48.57	39.43
WPP4’	2.89	2.23	56.12	44.58
WPP5’	2.32	1.95	43.78	41.19
WPP6’	2.81	2.14	54.95	48.71
WPP7’	2.50	2.03	49.72	39.88



Şekil 4.12 Düzeltilmiş NWP rüzgâr hızı ile ham NWP ve RWM rüzgâr hızı verileri tipik Weibull dağılımları

Biçim parametresinin düzeltilmiş NWP rüzgâr hızı verisinde yüksek çıkmasına rağmen özellikle ortalama hız ile ilişkili ölçek parametresinin RWM rüzgâr hızı ölçüm dağılımına çok yakın olması başarılı bir düzeltme olduğu sonucunu ortaya koymaktadır. Ancak önemli olan diğer bir nokta da dağılım biçiminde görünen düzeltilmiş NWP verileri özellikle rüzgârdan güce geçiş aşamasında telafi edilmiştir.

Son olarak geliştirilen model, adım adım her bir katmanın getirdiği iyileştirmeyi ortaya koyabilmek için üç farklı ara katman sonucu ile karşılaştırılmıştır. İlk olarak hiçbir korelasyon düzeltmesi ve rüzgâr örüntü tanıma olmadan yapılan tahmin sonuçları (Durum A) NMAE cinsinden hesaplanmıştır. İkinci olarak sadece RWM korelasyon düzeltmesi ile yapılan tahmin sonuçları hesaplanmıştır (Durum B). Son olarak ise sadece örüntü tanıma metodu eklenmiş halde yapılan tahmin sonuçları hesaplanmıştır (Durum C). Her aşamada elde edilen iyileştirmeleri ifade eden bu sonuçlar Çizelge 4.5'te verilmiştir.

Çizelge 4.5 NWP ve RWM veri korelasyonu ile rüzgâr örüntü tanıma yöntemlerinin rüzgârdan üretilen elektriksel güç tahminlerindeki iyileştirmeler
(Durum A: Hem RWM veri korelasyonu hem de örüntü tanıma yokken
Durum B: RWM veri korelasyonu var ancak örüntü tanıma yokken
Durum C: RWM veri korelasyonu yok ancak örüntü tanıma varken)

Santral	Durum A	Durum B	Durum C	Önerilen Metot
	NMAE (%)	NMAE (%)	NMAE (%)	NMAE (%)
WPP1'	13.42	10.06	11.72	8.36
WPP2'	10.02	8.91	8.82	7.71
WPP3'	14.85	12.16	12.78	10.09
WPP4'	11.94	9.66	11.00	8.72
WPP5'	11.55	9.89	10.02	8.36
WPP6'	11.38	9.63	9.36	7.61
WPP7'	11.40	8.97	10.07	7.64

5. SONUÇ

Bu tez çalışmasında ileri istatistiksel yöntemler kullanarak rüzgârdan üretilen elektriksel gücün tahmini çalışmaları yapılmıştır. Temel istatistiksel yöntemlerin yetersiz kaldığı noktalar belirlenerek yeni çok katmanlı yapılar oluşturulmuştur. Bu kapsamda iki farklı yaklaşım geliştirilerek “Türkiye’de Rüzgârdan üretilen Elektriksel Gücün Tahmini ve İzlenmesi (RİTM)” projesine dâhil olan WPP’ler için uygulanmıştır.

Önerilen modellerden birincisinde, çok katmanlı, kademeli, ileri istatistiksel metotları kombine eden yeni bir tahmin yöntemi önerilmiş ve Türkiye’de RİTM projesine dâhil olan ve toplam kurulu gücü yaklaşık 1.5 GW olan 25 büyük WPP için başarılı bir şekilde uygulanmıştır. Beş katmanlı olan ve ANN / SVM kombinasyonlarını içeren bu yapı ile 48-saat öncesi rüzgârdan üretilen elektriksel gücün tahminleri yapılmıştır. Model girdisi olarak üç farklı NWP modelinden (DMİ, GFS ve ECMWF) gelen rüzgâr verileri ile rüzgâr enerji analizörlerinden gelen elektriksel güç verileri kullanılmıştır. İlk olarak her bir WPP için çok sayıdaki meteorolojik NWP rüzgâr hızı ve yönü bilgilerinden oluşan grid verileri eğitim aşamasında en az MAE hatasını veren en iyi meteorolojik gridi bulmak için kullanılır. Daha sonra çoklu katman yapısı içerisinde ANN ve SVM kombinasyonları kullanılarak nihai rüzgârdan üretilen elektriksel güç üretim tahminleri yapılır. En az 12 aylık eğitim verisi kullanıldığında özellikle karmaşık arazi ve dağınık rüzgâr rejimine sahip santrallerde süreklilik modeli ile fiziksel ve hibrit diğer geleneksel modellerden daha iyi sonuçlar elde edilmiştir. Yöntemin uygulandığı 25 WPP’de NMAE değerlerinde % 26 ile % 56 aralığında süreklilik modeli üzerinde iyileştirme elde edilmiştir. Karmaşık arazili ve dağınık rüzgâr rejimine sahip santrallerde ise NMAE değerinde % 40’ın üzerinde iyileştirmeye ulaşılmıştır. Önerilen çok katmanlı kademeli ileri istatistiksel modellerden oluşan yapı, 48-saat öncesi tahminlerde, tek katmanlı yapıya oranla % 1.5 ile % 5.2 arasında değişen daha iyi NMAE değerlerine ulaşmıştır. Tüm santrallerde elde edilen ortalama hata değerleri incelendiğinde, özellikle 12 ay üzeri büyüklükte eğitim verisine sahip santrallerde, fiziksel modele oranla % 4.6’ya kadar, hibrit modele oranla ise % 1.9’a kadar NAME değerinde azalma elde edilmiştir. Önerilen metot ile elde edilen başarılı rüzgârdan üretilen elektriksel güç tahmin sonuçları, öncelikle uygun ağırlıklandırma değerleri kullanılarak ANN ve SVM modellerinin kombine edilmesinden kaynaklanmaktadır. Bu başarılı sonuçların diğer nedeni ise, en iyi grid seçimine dayanan çoklu NWP girdileri kullanan bir yapıya sahip olmasıdır.

Önerilen modellerden ikincisinde ise, rüzgâr örüntü tanıma ve RWM ile NWP verileri arasındaki korelasyona dayalı yeni bir yaklaşım önerilmiştir. Bu yöntem, Türkiye’de RİTM projesine dahil olan ve santral sahasına RWM kurulmuş yedi farklı WPP’ye uygulanarak rüzgârdan üretilen elektriksel güç üretim tahminleri iyileştirilmiştir. Üç farklı NWP girdi verisinden gelen meteorolojik grid verileri AdaBoost modeli ile kombine edilmiş ve elde edilen rüzgâr hızı ve yönü verileri optimum sınıf sayıları ile sınıflandırmaya tabi tutulmuştur. Elde edilen her sınıf verisi farklı ANN/SVM model setlerinin eğitiminde kullanılarak, RWM ölçüm verileri ile NWP verileri arasında korelasyon bulunmuş ve NWP tahminleri santral sahasına indirgenmiştir. Daha sonra rüzgâr örüntü tabanlı yeni bir yöntem uygulanarak rüzgârdan rüzgâra geçiş aşaması sonlandırılmıştır. Düzeltilmiş rüzgâr verileri kullanılarak yeni bir ANN/SVM seti ile rüzgârdan güce geçiş yapılarak, ham rüzgârdan üretilen elektriksel güç üretim tahminleri yapılmıştır. MOS modeli ile ham tahminler üzerindeki sistematik hatalar minimize edilmiş ve son aşamada ağırlıklandırılmış kombinasyon metodu ile ham tahminler nihai 48-saat öncesi rüzgârdan üretilen elektriksel güç tahminlerine dönüştürülmüştür. Geliştirilen model, 3.07 GHz i7 işlemci ve 16 GB RAM özelliklerine sahip kişisel bir bilgisayarda, yaklaşık 24 aylık eğitim verisi kullanılarak koşturulmuş ve hesaplama süresi yaklaşık 90 saniye olarak belirlenmiştir.

Elde edilen sonuçlar, önerilen ikinci metot ile yedi santral için rüzgârdan üretilen elektriksel gücün tahminlerinde NMAE değeri üzerinden süreklilik modeline göre % 25 ile % 71 aralığında düzeltme elde edildiğini göstermiştir. İki yıllık eğitim verisi ile altı aylık test periyotları kullanılmıştır. Diğer taraftan, geleneksel yöntemlere göre NMAE değerinde % 2.3 ile % 5.1 aralığında iyileşme elde edilmiştir. Bu iyileşme değerlerinin içerisindeki % 1.1 ile % 3.4 arasındaki WPP bazında iyileştirme, NWP verisi ile RWM verisi arasındaki korelasyondan kaynaklanırken, % 0.9 ile % 2.1 arasındaki iyileştirme ise tekrarlayan rüzgâr örüntülerini öğrenmeye dayalı yeni yaklaşımdan kaynaklanmıştır. Yeni önerilen model sonuçları, hibrit bir yöntem kullanan RİTM projesinin tahmin sonuçları ile karşılaştırılmış ve NMAE değerinde % 2.7 civarında bir iyileştirme elde edilmiştir.

Önerilen modellerin başarılı tahminler yapabilmesi için en az bir yıllık eğitim verisine ihtiyaç vardır. Bu düzeyde bir veri boyutu, her iki modelin ara tahmin modellerinin başarılı bir şekilde oluşturulmasını sağlamaktadır. Ayrıca birden çok NWP verisi kullanmak, her bir NWP’den kaynaklanan sistematik hataların azaltılmasını sağlayarak daha başarılı rüzgârdan üretilen elektriksel gücün tahminlerinin yapılmasını sağlamaktadır.

Geliştirilen ilk modelde, 25 santralin her birinin tahmininde kullanılan tüm veriler 2.6 GHz frekansında 24 çekirdekli işlemci, 64 GB RAM ve 24 TB sabit disk özelliklerine sahip bir sunucu bilgisayar üzerinde tutulmaktadır. NWP verileri, her bir santral için önce en yakın 100 gride daha sonra modellerde kullanılmak üzere en yakın dokuz grid verisine indirgenerek analizler yapılmakta ve tahminler çıkarılmaktadır. Santral bazında tek bir grid içerisinde yaklaşık 2.1 MB boyutunda veri bulunurken 100 grid verisi analiz edilirken bu veri boyutu 210 MB olmaktadır. Her bir santral için DMİ NWP verileri için veri tabanında yaklaşık 117.8 GB boyutunda bir veri söz konusu iken GFS ve ECMWF NWP verileri için ise yaklaşık 11.3 GB boyutunda veri boyutları söz konusu olmaktadır. Geliştirilen model, veri tabanı sunucuları üzerinde her bir santral için bir yıllık eğitim verisi için yaklaşık 210 saniye (3.5 dakika) hesaplama süresine ihtiyaç duymaktadır. Veri sayısı arttıkça hesaplama süresi de artmaktadır. Geliştirilen ikinci modelde ise, 3.07 GHz i7 işlemci ve 16 GB RAM özelliklerine sahip kişisel bir bilgisayarda, yaklaşık 24 aylık eğitim verisi kullanılarak koşturulmuş ve hesaplama süresi yaklaşık 90 saniye olarak belirlenmiştir.

Tez çalışması kapsamında geliştirilen her iki metot da literatürdeki rüzgârdan üretilen elektriksel gücün tahmini çalışmalarına yeni bakış açıları kazandırmış ve başarılı sonuçlar elde edilmiştir. Önerilen yöntemler hem gerçek zamanlı hem de gerçek zamanlı olmayan uygulamalarda kullanılabilen özgün yaklaşımlar olmuştur.

KAYNAKLAR

- [1] A.U. Haque, M.H. Nehrir, P. Mandal, "A Hybrid Intelligent Model for Deterministic and Quantile Regression Approach for Probabilistic Wind Power Forecasting," *IEEE Transactions on Power Systems*, vol.29, no.4, pp.1663-1672, **2014**
- [2] R. J. Bessa, V. Miranda, and J. Gama, "Entropy and correntropy against minimum square error in offline and online three-day ahead wind power forecasting," *IEEE Transactions on Power Systems*, vol. 24, no. 4, pp. 1657–1666, **2009**.
- [3] Y. K. Wu and J. S. Hong, "A literature review of wind forecasting technology in the world," *IEEE Power Tech Conference*, pp. 504–509, Jul. **2007**.
- [4] L. Jones and C. Clark, "Wind integration - a survey of global views of grid operators," *10th International Workshop on Large-Scale Integration of Wind Power into Power Systems*, **2011**.
- [5] L. Ma, S. Y. Luan, C. W. Jiang, H. L. Liu, and Y. Zhang, "A review on the forecasting of wind speed and generated power," *Renewable & Sustainable Energy Reviews*, vol. 13, no. 4, pp. 915-920, **2009**.
- [6] A. Costa, A. Crespo, J. Navarro, G. Lizcano, H. Madsen, and E. Feitosa, "A review on the young history of the wind power short-term prediction," *Renewable & Sustainable Energy Reviews*, vol. 12, no. 6, pp. 1725-1744, **2008**.
- [7] G. Giebel, R. Brownsword and G. Kariniotakis, *The State-of-the-Art in Short-Term Prediction of Wind Power: A Literature Overview, 2nd edition*, ANEMOS.plus, Roskilde, Denmark, Technical Report, **2011**,
- [8] C. Monteiro, R. Bessa, V. Miranda, A. Botterud, J. Wang and G. Conzelmann, *Wind Power Forecasting: State-of-the-Art 2009*, Argonne National Laboratory, Technical Reports, ANL/DIS-10-1, **2009**.
- [9] J.P.S. Catalão, H.M.I. Pousinho, V.M.F. Mendes, "Hybrid intelligent approach for short-term wind power forecasting in Portugal," *IET Renewable Power Generation*, vol. 5, no. 3, pp.251-257, **2011**.
- [10] M. Ozkan, P. Karagoz, "A Novel Wind Power Forecast Model: Statistical Hybrid Wind Power Forecast Technique (SHWIP)," *IEEE Transactions on Industrial Informatics*, vol. 11, no. 2, pp.375-387, **2015**.
- [11] M. Lange and U. Focken, *Physical Approach to Short-term Wind Power Prediction*, Springer Berlin, **2005**.
- [12] S.Shokrzadeh, M. Jafari Jozani, E. Bibeau, "Wind Turbine Power Curve Modeling Using Advanced Parametric and Nonparametric Methods," *IEEE Transactions on Sustainable Energy*, vol. 5, no. 4, pp.1262-1269, **2014**.
- [13] H.R. Glahn and D.A. Lowry, "The use of Model Output Statistics (MOS) in objective weather forecasting," *Journal of Applied.Meteorology*, vol. 11, no. 8, pp. 1202-1211, **1972**.
- [14] N. Chen, Z. Qian, IT. Nabney, Xiaofeng Meng, "Wind Power Forecasts Using Gaussian Processes and Numerical Weather Prediction," *IEEE Transactions on Power Systems*, vol. 29, no. 2, pp.656-665, **2014**

- [15] S. Buhan, I. Cadirci, "Multi-Stage Wind-Electric Power Forecast by Using a Combination of Advanced Statistical Methods," *IEEE Transactions on Industrial Informatics*, vol.11, no.5, pp.1231-1242, **2015**.
- [16] A. Kavousi-Fard, A. Khosravi, and S. Nahavandi, "A New Fuzzy-Based Combined Prediction Interval for Wind Power Forecasting," *IEEE Transactions on Power Systems*, early access paper, doi: 10.1109/TPWRS.2015.2393880.
- [17] N. Amjady, F. Keynia, and H. Zareipour, "Wind Power Prediction by New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization," *IEEE Transactions on Sustainable Energy*, vol. 2, no. 3, pp. 265-276, **2011**.
- [18] H. Liu, E. Erdem, and J. Shi, "Comprehensive evaluation of ARMA arch(-m) approaches for modeling the mean and volatility of wind speed," *Appl. Energy*, vol. 88, no. 3, pp. 724-732, **2011**.
- [19] R. G. Kavasseri and K. Seetharaman, "Day-ahead wind speed forecasting using f-ARIMA models," *Renewable Energy*, vol. 34, no. 5, pp.1388–1393, **2009**.
- [20] P. Louka, G. Galanis, N. Siebert, G. Kariniotakis, P. Katsafados, I. Pytharoulis, and G. Kallos, "Improvements in wind speed forecasts for wind power prediction purposes using Kalman filtering," *Journal of Wind Engineering & Industrial Aerodynamics*, vol. 96, no. 12, pp. 2348–2362, **2008**.
- [21] IG. Damousis, M.C. Alexiadis, J.B. Theocharis, P.S. Dokopoulos, "A fuzzy model for wind speed prediction and power generation in wind parks using spatial correlation," *IEEE Transactions on Energy Conversion*, vol. 19, no. 2, pp.352-361, **2004**.
- [22] G. Li and J. Shi, "On comparing three artificial neural networks for wind speed forecasting," *Applied Energy*, vol. 87, no. 7, pp. 2313-2320, **2010**.
- [23] J. Zhou, J. Shi, and G. Li, "Fine tuning support vector machines for short-term wind speed forecasting," *Energy Conversion & Management*, vol. 52, no. 4, pp. 1990-1998, **2011**.
- [24] Catalao, J.P.S., Pousinho, H.M.I. and Mendes, V.M.F., "An Artificial Neural Network Approach for Short-Term Wind Power Forecasting in Portugal," *15th International Conference on Intelligent System Applications to Power Systems*, vol., no., pp.1-5, 8-12, **2009**
- [25] C.S. Ioakimidis, L.J. Oliveira, K.N. Genikomsakis, " Wind Power Forecasting in a Residential Location as Part of the Energy Box Management Decision Tool," *IEEE Transactions on Industrial Informatics*, vol. 10, no. 4, pp.2103-2111, **2014**.
- [26] A. U. Haque, P. Mandal, J. Meng, A. K. Srivastava, T.-L. Tseng, and T. Senjyu, "A Novel Hybrid Approach Based on Wavelet Transform and Fuzzy ARTMAP Networks for Predicting Wind Farm Power Production," *IEEE Transactions on Industrial Applications*, vol. 49, no. 5, pp. 2253–2261, **2013**.
- [27] A. Kusiak, Z. Haiyang, S. Zhe, "Short-Term Prediction of Wind Farm Power: A Data-Mining Approach," *IEEE Transactions on Energy Conversion*, vol. 24, no. 1, pp. 125-136, **2009**.
- [28] K. Sreelakshmi, P. Ramakanthkumar, "Short Term Wind Speed Prediction Using Support Vector Machine Model," *WSEAS Transaction on Computer Science*, vol. 7, no. 11, pp. 1828-1837, **2008**.

- [29] M. Mohandes, T. Halawani, S. Rehman, and A. A. Hussain, "Support vector machines for wind speed prediction," *Renewable Energy*, vol. 29, no. 6, pp. 939-947, **2004**.
- [30] Yongqian Liu, Jie Shi, Yongping Yang, Wei-Jen Lee, "Short-Term Wind-Power Prediction Based on Wavelet Transform-Support Vector Machine and Statistic-Characteristics Analysis," *IEEE Transaction on Industrial Applications*, vol. 48, no. 4, pp. 1136-1141, **2012**.
- [31] T. Barbounis and J. Theocharis, "Locally recurrent neural networks for wind speed prediction using spatial correlation," *Information Sciences*, vol. 177, no. 24, pp. 5775-5797, **2007**.
- [32] T. Barbounis, J. Theocharis, M. Alexiadis, and P. Dokopoulos, "Longterm wind speed and power forecasting using local recurrent neural network models," *IEEE Transaction on Energy Conversion*, vol. 21, no. 1, pp. 273-284, **2006**.
- [33] N. Amjady, F. Keynia, and H. Zareipour, "Short-term wind power forecasting using ridgelet neural network," *Electric Power System Research*, vol. 81, no. 12, pp. 2099-2107, **2011**.
- [34] M. G. De Giorgi, A. Ficarella, and M. Tarantino, "Error analysis of short term wind power prediction models," *Applied Energy*, vol. 88, no. 4, pp. 1298-1311, **2011**.
- [35] S. Tewari, C.J. Geyer, N. Mohan, "A Statistical Model for Wind Power Forecast Error and its Application to the Estimation of Penalties in Liberalized Markets," *IEEE Transactions on Power Systems*, vol. 26, no. 4, pp. 2031-2039, **2011**.
- [36] G.J. Osório, J.C.O. Matias, J.P.S. Catalão, "A review of short-term wind power forecasting approaches," *IET Renewable Power Generation Conference*, pp. 1-4, **2013**.
- [37] G. Sideratos, N.D. Hatziargyriou, "Wind Power Forecasting Focused on Extreme Power System Events," *IEEE Transactions on Sustainable Energy*, vol. 3, no. 3, pp. 445-454, **2012**.
- [38] I. J. Ramirez-Rosado, L. A. Fernandez-Jimenez, C. Monteiro, J. Sousa, and R. Bessa, "Comparison of two new short-term wind-power forecasting systems," *Renewable Energy*, vol. 34, no. 7, pp. 1848-1854, **2009**.
- [39] M. C. Alexiadis, P. S. Dokopoulos, and H. S. Sahsamanoglou, "Wind speed and power forecasting based on spatial correlation models," *IEEE Transactions on Energy Conversion*, vol. 14, no. 3, pp. 836-842, **1999**.
- [40] G. Giebel, L. Landberg, G. Kariniotakis, and R. Brownsword, "State-of-the-art on methods and software tools for short-term prediction of wind energy production," *EWECE*, Madrid, Spain, **2003**.
- [41] L. Landberg, G. Giebel, H. A. Nielsen, T. Nielsen, and H. Madsen, "Short-term prediction-An overview," *Wind Energy (Special Review Issue on Advances in Wind Energy)*, vol. 6, no. 3, pp. 273-280, **2003**.
- [42] N. Amjady, F. Keynia and H. Zareipour, "Wind Power Prediction by a New Forecast Engine Composed of Modified Hybrid Neural Network and Enhanced Particle Swarm Optimization", *IEEE Transactions on Sustainable Energy*, vol.2, no.3, pp.265-276, **2011**.

- [43] Soman, S.S., Zareipour, H., Malik, O. and Mandal, P., "A review of wind power and wind speed forecasting methods with different time horizons," *North American Power Symposium (NAPS)*, pp.1-8, **2010**
- [44] Q. Xu, D. He, N. Zhang, C. Kang, Q. Xia, J. Bai, and J. Huang, "A Short-Term Wind Power Forecasting Approach With Adjustment of Numerical Weather Prediction Input by Data Mining," *IEEE Transactions on Sustainable Energy*, vol.6, no.4, pp.1283-1291, **2015**.
- [45] C. Mingjian, K. Deping, S. Yuanzhang, G. Di, Z. Jie, B.-M. Hodge, "Wind Power Ramp Event Forecasting Using a Stochastic Scenario Generation Method," *IEEE Transactions on Sustainable Energy*, vol.6, no.2, pp.422-433, **2015**.
- [46] G. Sideratos and N. D. Hatziargyriou, "An advanced statistical method for wind power forecasting," *IEEE Transactions on Power Systems*, vol. 22, no. 1, pp. 258-265, **2007**.
- [47] M. Khalid, A.V. Savkin, "A Method for Short-Term Wind Power Prediction With Multiple Observation Points," *IEEE Transactions on Power Systems*, vol. 27, no. 2, pp. 579-586, **2012**.
- [48] F. Shu, J.R. Liao, R. Yokoyama, C. Luonan, L. Wei-Jen, "Forecasting the Wind Generation Using a Two-Stage Network Based on Meteorological Information," *IEEE Transactions on Energy Conversion*, vol. 24, no. 2, pp. 474-482, **2009**.
- [49] K. Bhaskar, S.N. Singh, "AWNN-Assisted Wind Power Forecasting Using Feed-Forward Neural Network," *IEEE Transactions on Sustainable Energy*, vol. 3, no. 2, pp. 306-315, **2012**.
- [50] P. Pinson, H. Nielsen, H. Madsen, and G. Kariniotakis, "Skill forecasting from ensemble predictions of wind power," *Applied Energy*, vol. 86, no. 7-8, pp. 1326-1334, **2009**.
- [51] J.L. Wu, T.Y. Ji, M.S. Li, P.Z. Wu and Q.H. Wu, "Multistep Wind Power Forecast Using Mean Trend Detector and Mathematical Morphology-Based Local Predictor," *IEEE Transactions on Sustainable Energy*, vol. 6, no. 4, pp. 1216–1223, **2015**.
- [52] H.B. Azad, S. Mekhilef, V. G. Ganapathy, "Long-Term Wind Speed Forecasting and General Pattern Recognition Using Neural Networks," *IEEE Transactions on Sustainable Energy*, vol.5, no.2, pp.546-553, **2014**.
- [53] Hu Qinghua, Su Pengyu, Yu Daren, Liu Jinfu, "Pattern-Based Wind Speed Prediction Based on Generalized Principal Component Analysis," *IEEE Transactions on Sustainable Energy*, vol.5, no.3, pp.866-874, **2014**.
- [54] Electric Power Research Institute Inc. (EPRI), *California Wind Energy Forecasting System Development and Testing, Phase 2: 12-Month Testing*, Palo Alto, CA, USA, Technical Report, 1007339, **2003**
- [55] M.A. Gaertner, C. Gallardo, C. Tejada, N. Martínez, S. Calabria, N. Martínez, and B. Fernández, "The Casandra project: results of wind power 72-hr range daily operational forecasting in Spain," *European Wind Energy Conference*, Madrid, Spain, **2003**.
- [56] Anonim, *MeteoLógica*, <http://www.meteologica.com>, (Aralık, **2014**).

- [57] M. Lange and U. Focken, "State-of-the-art in wind power prediction in Germany and international developments," *2nd International Workshop Feed-In Cooperation*, Berlin, **2005**.
- [58] Robert Kelly, "New modeling techniques: from wind assessment and forecasting to wind resource management," *Bonneville Power Administration & California ISO's International Wind Forecast Techniques and Methodologies Workshop*, Portland, Oregon, **2008**.
- [59] Nicholas Cutler, Kieran Jacka, T. S. Nielsen, and Merlinde Kay, "The First Australian Installation of the Wind Power Prediction Tool," in *Proc. Global Wind Energy Conf.*, Adelaide, Australia, **2006**.
- [60] R. Costello, D. McCoy, P. O'Donnell, A.G. Dutton, and G. Kariniotakis, "Potential Benefits of Wind Forecasting and the Application of More-Care in Ireland," *3rd MED POWER Conference*, Athens, Greece, **2002**.
- [61] Ue. Cali, B. Lange, J. Dobschinski, M.Kurt, C. Moehrlen, and B. Ernst, "Artificial neural network based Wind Power Forecasting using a multi-model approach," *7th International Workshop on Large Scale Integration of Wind Power and on Transmission Networks for Offshore Wind Farms*, Madrid, Spain, **2008**.
- [62] J. Usaola, O. Ravelo, I. Sánchez, C. Velasco, J. Domínguez, M. Lobo, G. M. González, F. Soto, "Sipreólico: a wind power prediction tool for the Spanish peninsular power system operation," *European Wind Energy Conference*, **2002**.
- [63] Anonim, AleaSoft, <http://www.aleasoft.com> (Aralık, **2014**).
- [64] G. Gow, *Forecasting Short-Term Wind Farm Production*, Garrad Hassan and Partners Ltd., Bristol, U.K., Technical Report, **2003**.
- [65] A. Rodrigues, J.A. Peças Lopes, P. Miranda, L. Palma, C. Monteiro, R. Bessa, J. Sousa, C. Rodrigues, and J. Matos, "EPREV-A Wind Power Forecasting Tool for Portugal," *European Wind Energy Conference*, Milan, Italy, **2007**.
- [66] Windlogics Inc., *Renewable Energy Research and Development Project-Final Report*, Technical Report, **2008**.
- [67] Kristen Larson, "State-of-the Art in Wind Forecasting," *Putting Wind on the Wires-Arizona Wind Power Forum Friday*, Phoenix, Arizona, **2008**.
- [68] U. Focken, M. Lange, and H.P. Waldl, "Previento-A Wind Power Prediction System with an Innovative Upscaling Algorithm," *European Wind Energy Conference*, Copenhagen, Denmark, pp. 826-829, **2001**.
- [69] S. Lang, J. Möhrlein, J. Jørgensen, B.O. Gallachóir, and E. McKeogh, "Aggregate forecasting of wind generation on the Irish grid using a multi-scheme ensemble prediction system," *2nd Int. Renewable Energy in Maritime Island Climates Conference*, Dublin, Ireland, **2006**.
- [70] L.Frias, E.Pascal, et al., "Support Vector Machines in the wind energy framework A new model for wind energy forecasting", *European Wind Energy Conference*, Marseille, France, **2009**.
- [71] G. Giebel, L. Landberg, T.S. Nielsen, and H. Madsen, "The Zephyr Project-The Next Generation Prediction System," *Global Windpower Conference and Exhibition*, Paris, France, **2002**.
- [72] Anonim, Scirocco, <http://www.windknowhow.com>, (Aralık, **2015**).

- [73] J.W. Zack, "An overview of AWS Truewind's approach and experience in providing wind power production forecasting services to utilities and balancing authorities in North America," *International Wind Forecasting Workshop Portland, Oregon*, **2008**.
- [74] E. McCarthy, R. Nierenberg, L. Landberg, J. Zack, and K. Tran, *Texas Wind Energy Forecasting System Development and Testing. Phase 2: 12-Month Testing*, Technical Report, **2004**.
- [75] E. Terciyanli, T. Demirci, D. Kucuk, M. Sarac, I. Cadirci, M. Ermis, "Enhanced Nationwide Wind-Electric Power Monitoring and Forecast System," *IEEE Transactions on Industrial Informatics*, vol. 10, no. 2, pp.1171-1184, **2014**.
- [76] Song Li, Peng Wang, Goel, L., "Wind Power Forecasting Using Neural Network Ensembles With Feature Selection," *IEEE Transactions on Sustainable Energy*, vol.6, no.4, pp.1447-1456, **2015**
- [77] Guannan Qu; Jie Mei; Dawei He, "Short-term wind power forecasting based on numerical weather prediction adjustment," *11th IEEE International Conference on Industrial Informatics (INDIN)*, vol., no., pp.453-457, **2013**
- [78] T. Demirci, A. Kalaycıoğlu, D. Küçük *et al.*, "Nationwide real-time monitoring system for electrical quantities and power quality of the electricity transmission system," *IET Generation, Transmission & Distribution*, vol. 5, no. 5, pp. 540-550, **2011**.
- [79] Kusiak, A., Zijun Zhang, "Short-Horizon Prediction of Wind Power: A Data-Driven Approach," *IEEE Transactions on Energy Conversion*, vol.25, no.4, pp.1112-1122, **2010**.
- [80] C. Igel and M. Hüsken, "Improving the Rprop Learning Algorithm," *2nd International Symposium on Neural Computation*, ICSC Academic Press, pp. 115-121, **2000**.
- [81] Chih-Wei Hsu, Chih-Chung Chang, and Chih-Jen Lin, *A Practical Guide to Support Vector Classification*, **2003**.
- [82] D. Lei, R. Liang, G. Shuang, G. Yang, and L. Xiaozhong, "Studies on wind farms ultra-short term NWP wind speed correction methods," *IEEE conference on Control and Decision*, pp. 1576-1579, **2013**.
- [83] N. Fisher and A. Lee, "A correlation coefficient for circular data," *Biometrika*, vol. 70, no. 2, pp. 327-332, **1983**.
- [84] A. Couto, P. Costa, L. Rodrigues, V.V. Lopes, and A. Estanqueiro, "Impact of Weather Regimes on the Wind Power Ramp Forecast in Portugal," *IEEE Transactions on Sustainable Energy*, vol.6, no.3, pp.934-942, **2015**.
- [85] Anonim, RİTM, <http://www.ritm.gov.tr>, (Aralık, **2015**).
- [86] W. S. McCulloch and W. H. Pitts. *A logical calculus of the ideas immanent in nervous activity*. Bulletin of Mathematical Biophysics, 5:115-133, **1943**.
- [87] F. Rosenblatt. *The perceptron: a probabilistic model for information storage and organization in the brain*. Psychological Review, 65:386-408, **1958**.
- [88] L. Yang, M. He, J. Zhang, and V. Vittal, "Support-Vector-Machine-Enhanced Markov Model for Short-Term Wind Power Forecast," *IEEE Transactions on Sustainable Energy*, vol.6, no.3, pp.791-799, **2015**.

- [89] D. L. Shrestha and D. P. Solomatine, “Experiments with AdaBoost. RT, an improved boosting scheme for regression,” *Neural Computation*, vol. 18, no. 7, pp. 1678–1710, **2006**.
- [90] Anonim, NWP, <http://www.mgm.gov.tr>, (Aralık, **2015**).
- [91] Anonim, ALADIN, <http://www.cnrm.meteo.fr/aladin>, (Aralık, **2015**).
- [92] Anonim, WRF, <http://www.wrf-model.org/index.php>, (Aralık, **2015**).
- [93] Anonim, GFS, <https://www.ncdc.noaa.gov/data-access/model-data/model-datasets/numerical-weather-prediction>”, (Aralık, **2015**).
- [94] Anonim, ECMWF, <http://www.ecmwf.int/en/about/what-we-do/numerical-weather-forecasts>”, (Aralık, **2015**).

EKLER

EK-1 TÜRKÇE-İNGİLİZCE TERİMLER SÖZLÜĞÜ

Adaptif Arttırma	: Adaptive Boosting
Bulanık Mantık	: Fuzzy Logic
Çok katmanlı Algılayıcı	: Multi Layer Perceptron
Destek Vektör Makinaları	: Support Vector Machines
Gradyan Azalış	: Gradient descent
Kök Ortalama Kare Hata	: Root Mean Square Error
K-means Sınıflandırma	: K-means Clustering
Model Çıktı İstatistiği	: Model Output Statistics
Normalize Ortalam Mutlak Hata	: Normalize Mean Absolute Error
Rüzgâr Gözlem İstasyonu	: Referans Wind Mast
Rüzgâr Enerjisi Analizörü	: Wind Energy Analyzer
Rüzgâr Güç Santrali	: Wind Power Plant
Sayısal Hava Tahminleri	: Numerical Weather Predictions
Süreklilik Modeli	: Persistence Model
Yapay Sinir Ağları	: Artificial Neural Networks

EK-2 TEMEL İSTATİSTİKSEL MODEL YAKLAŞIMLARI

Doğrusal temelli modeller, doğrusal olmayan sistem modellemelerinde daha fazla hata yapmaktadırlar. Bu nedenle rüzgâr tabanlı bir tahmin sisteminde rüzgârın doğrusal olmayan değişimi dikkate alındığında, modelleme yönteminin de doğrusal olmayan bir modelleme yöntemi olması gerekmektedir. Hem literatürden elde edilen sonuçlar ışığında hem de tahmin yöntemlerinin değerlendirilerek uygulanması aşamasında en iyi sonuçların doğrusal olmayan istatistiksel tahmin modelleri ile elde edilebildiği anlaşılmaktadır. Bu tez çalışmasında doğrusal olmayan bu istatistiksel tahmin modellerinden ANN ve SVM modellerinin bir arada kullanıldığı metotlar geliştirilmiştir. Diğer taraftan K-means sınıflandırma modeli de benzer özelliklere sahip rüzgâr verilerinin aynı sınıflara ayrılmasını sağlayarak rüzgârdan üretilen elektriksel güç üretim tahminlerinin performansını arttırmaya katkı sağlamaktadır. Ayrıca çok sayıda NWP grid verilerinin optimize edilerek en iyi rüzgâr verisine dönüştürme yaklaşımı için Adaptif Arttırma (AdaBoost) yöntemi kullanılmış ve tez içerisinde tahmin doğruluğunu arttırmada başarılı olmuştur. Tüm bu istatistiksel modeller için detaylı teorik açıklamalar izleyen alt başlıklarda sırasıyla verilmiştir.

ANN Modeli

İstatistiksel ANN modeli temel olarak sinir sistemi mantığıyla her bir geçmiş bilgiyle elde edilecek algının tahmine yansıtılmasıyla oluşmaktadır. Grafikselsel olarak sinir ağı modeli Şekil 0.1(a)'da gösterilmiştir.

ANN modeli uygun şekilde oluşturulmuş eğitim seti ile öğretilerek çok sayıda doğrusal olmayan problemin çözümünde etkin rol oynayabilmektedir. Rüzgâr ve yük tahminleri, medikal teşhis, nesne sınıflandırma ve örüntü tanıma gibi birçok alanda sıklıkla kullanılan bir yöntem olarak karşımıza çıkmaktadır.

ANN Yapısı:

ANN yapısı insan beyni yapısından esinlenerek oluşturulduğu için temel yapı birimleri de nöron olarak adlandırılmaktadır. Yapay bir nöron hücresi, biyolojik nöron hücresine benzer şekilde Şekil 0.1(b)'de gösterildiği gibi modellenmiştir [86]. Girdi verileri belirli ağırlık değerleri ile çarpıldıktan sonra toplam modülünde ve sonrasında aktivasyon fonksiyonu modülünden geçerek nöron çıktısını üretir.


Nöronun çıktı değerleri doğrusal olmayan aktivasyon fonksiyonları sayesinde modellenilebilir ve toplam çıktı fonksiyonu v , Eşitlik (0.1)'de şöyle ifade edilebilir.

$$v = b_0 + x_1 w_1 + x_2 w_2 + \dots + x_N w_N = \sum_{j=1}^N x_j w_j + b_0 \quad (0.1)$$


burada, x_j girdi verisini, w_j ağırlık katsayılarını, N eğitim girdi veri sayısını ve b ise nöron için bias terimini göstermektedir. Toplam fonksiyonu v , Eşitlik (0.2)'de gösterildiği gibi aktivasyon fonksiyonu φ 'den geçirilir.

$$y = \varphi(v) \quad (0.2)$$

burada, y , nöronun çıktı değerini göstermektedir. ANN modelinin hangi problemin çözümünde kullanılacağına bağlı olarak aktivasyon fonksiyonu, doğrusal, eşik, sigmoid, tanjant v.b. birçok fonksiyon türü olabilir.



(a)



(b)

Şekil 0.1 ANN model yapıları (a) Genel ANN modeli (b) Yapay bir nöron modeli

Rüzgâr üretim tahminlerinde sıklıkla kullanılan ve rüzgâr verisinin pozitif değerler almasından dolayı aktivasyon fonksiyonu olarak, Eşitlik (0.3)'te verilen sigmoid aktivasyon fonksiyonu kullanılmıştır.

$$\varphi = \frac{1}{1+\exp(\alpha z)} \quad (0.3)$$

burada, α aktivasyon fonksiyonu eğim parametresini ve z ise fonksiyon girdisini ifade etmektedir. Bu fonksiyon nöron çıkışına eklendiğinde nöron için çıkışta elde edilen çıktı değeri Eşitlik (0.4)'te verildiği gibi hesaplanabilir.

$$y = \frac{1}{1+\exp(-\alpha v)} \quad (0.4)$$

Tek başına bir nöron yapısının işlem kabiliyeti ve bilgi kapasitesi doğrusal olmayan karmaşık problemlerin çözümünde yetersiz kalmaktadır. Bu nedenle çok sayıda nöron yapısının birbirine bağlanması ile ilk olarak perseptron yapısı elde edilmiştir [87]. Bu yapı karmaşık problemlerin bazılarında sorun yaşasa da sinir ağı yapısının benzetimi için yapılan ilk başarılı sistem olmuştur.

Özellikle doğrusal olmayan problemlerin çözümünde perseptrondan daha öncesi bir yaklaşım olan çok katmanlı ileri beslemeli ANN yapıları kullanılmaktadır. Bu yapı içerisinde giriş, çıkış ve gizli katman olmak üzere üç ayrı katman bulunmaktadır. Gizli katman sayısı kullanılan probleme özel olarak birden fazla sayıda tasarlanabilir. Giriş katmanında modele verilen girdi yapısı ve sayısına göre değişmektedir. Çıkış katmanında ise problemin çözümünde istenen cevaba göre nöron sayısı belirlenir. Ancak nöron sayısındaki en kritik nokta gizli katmanda kullanılacak nöron sayısıdır. Tüm model performansı bu sayısından etkilenmektedir. İyi optimize edilmiş bir gizli katman nöron sayısı başarılı sonuçlar verirken, kötü optimize edilmiş gizli katman nöron sayısı ise başarısız sonuçlar verebilmektedir. Buradaki en temel yaklaşım gizli katman sayısındaki benzer şekilde çözülmek istenen probleme özel gizli katman nöron sayılarını belirlemektir.

ANN Modeli Eğitimi

ANN eğitim aşamasında, her bir iterasyonda elde edilen çıktı değeri hedef değerle karşılaştırılarak nöronun çıktı hatası hesaplanır. Daha sonra hatayı minimize edebilmek için geri bildirim ile bu hatalar önceki katmanlara iletilerek ağırlık ve bias değerleri değiştirilir. Tipik olarak sinir ağları modeli yüzlerce ağırlık değerine sahip olabilir. Bu değerler optimizasyon yöntemi ile belirlenir. Hata ağırlıkların bir fonksiyonu olarak ifade edilir. Amaç bu fonksiyonun global minimum değerini bulmaktır. Kullanılacak

optimizasyon yönteminin lokal bir minimumda takılıp kalmaması çok önemlidir. Bu nedenle algoritma her seferinde farklı bir başlangıç noktasından başlayarak global minimuma gitmelidir.

Literatürde sıklıkla kullanılan optimizasyon metotlarından biri Levenberg-Marquardt optimizasyonunda $E(\Theta)$ hata fonksiyonu olarak ifade edilirse Eşitlik (0.5)'teki gibi,

$$\theta_{next} = \theta_{now} - \eta(H + \lambda I)^{-1} \zeta \quad (0.5)$$

ifadesi bir sonraki adımda hata fonksiyonunun hesaplanacak değerinin bulunmasını sağlar. Burada θ_{next} , θ_{now} noktasından itibaren gradyanın ters yönünde atılan bir sonraki adımı ifade etmektedir. Ayrıca η , adım büyüklüğünü H , Hessian matrisini, I birim matrisi λ skalar değeri ζ ise gradyanı ifade etmektedir.

İleri beslemeli geri yayılım algoritması ile her bir sinir hücresi bir diğer sinir hücresi ile iletişime geçerek doğru ağırlık değerlerini elde etmeye çalışır.

Geri yayılım algoritmasının özeti ise şöyle ifade edilebilir.

- İklendirme: Sinaptik ağırlıkları ve limitleri düzgün dağılımlı rastgele değerlerden seçilir.
- Öğrenme Örneklerinin Sunumu: Ağ bir döngü için öğrenme örneklerine uygulanır.
- İleri Hesaplama: Bir öğrenme örneği için $x(n)$ (girdi vektörü) çok katmanlı yapıya yaydırılır. $d(n)$ (beklenen çıkış) hesaplama ağına çıkış katmanına yaydırılır. Ağın indüklenen lokal alanları ve fonksiyon sinyallerini ileri adımla katman katman hesaplanır. Burada l katmanında j siniri için indüklenen lokal alan değeri,

$$v_j^l(n) = \sum_{i=0}^{m_0} \omega_{ji}^l(n) y_i^{l-1}(n) \quad (0.6)$$

ile bulunur. Burada $y_i^{l-1}(n)$, n . yinelemede önceki $l-1$ katmanından gelen i nöronunun çıkış sinyalini ifade eder. $\omega_{ji}^l(n)$ ise $l-1$ katmanındaki i sinirinin beslediği l katmanındaki j sinirinin sinaptik ağırlığını ifade eder. $y_0^{l-1}(n) = 1$ ve $\omega_{j0}^l(n) = b_j^l(n)$ ise l katmanında j sinirine uygulanan bias değerini ifade eder. Örneğin sigmoid aktivasyon fonksiyonu kullanılırsa, l katmanında j siniri için çıkış sinyali:

$$y_j^l = \varphi_j(v_j(n)) \quad (0.7)$$

şeklinde ifade edilebilir. Burada φ aktivasyon fonksiyonunu ifade eder. Eğer j siniri birinci gizli katmanda ise

$$y_j^0 = x_j(n) \quad (0.8)$$

olarak yazılabilir. Burada $x_j(n)$, girdi vektörünün j . elemanı olarak ifade edilir.

Eğer j siniri çıkış katmanında ise

$$y_j^l = o_j(n) \quad (0.9)$$

olarak ifade edilir. Buradan hata sinyali ise

$$e_j(n) = d_j(n) - o_j(n) \quad (0.10)$$

şeklinde ifade edilir. Burada $d_j(n)$ beklenen çıkış $d(n)$ 'nin j . elemanı olarak tanımlanır.

- Geriye Doğru Hesaplama: Aşağıda tanımlı olan ağ için lokal gradyanları δ hesaplanır.

$$\delta_j^l(n) = e_j^l(n) \phi_j'(v_j^l(n)) \quad L \text{ çıkış katmanında } j \text{ siniri için} \quad (0.11)$$

$$\delta_j^l(n) = \phi_j'(v_j^l(n)) \sum_k \delta_k^{l+1}(n) \omega_{kj}^{l+1}(n) \quad l \text{ gizli katmanında } j \text{ siniri için} \quad (0.12)$$

Genelleştirilmiş delta kuralına göre l katmanındaki sinaptik ağırlıklar değiştirilir.

$$\omega_{ji}^l(n+1) = \omega_{ji}^l(n) + \alpha[\omega_{ji}^l(n-1)] + \eta \delta_j^l(n) y_i^{l-1}(n) \quad (0.13)$$

Burada η öğrenme hızı ve α ise momentum sabitidir.

- Yineleme: Durma koşuluna ulaşına dek devam et.

Yukarıda örnek bir öğrenme algoritması ve sinaptik ağırlıkların hesabı için örnek geri yayılım algoritmasına yer verilmiştir. Temel olarak aynı algoritma üzerinden farklı aktivasyon fonksiyonları ve iterasyon sayısı olarak tanımlanan farklı yineleme değerleri kullanılarak hata fonksiyonunun global minimuma ulaşmasına çalışılır. Öğrenme algoritması için birçok farklı fonksiyon kullanılabilir. Bunlar arasında gradyan azalış (gradient descent), BFGS Quasi-Newton v.b. algoritmalar gösterilebilir. Bu tez çalışmasında ise sıklıkla yığın tip esnek geri yayılım algoritması (Batch Type Resilient Back Propagation, BTRBP) kullanılmıştır.

ANN eğitim aşamasında bastırma fonksiyonları olarak adlandırılan sigmoid aktivasyon fonksiyonları sıklıkla kullanılır. Bu fonksiyon çok geniş aralık ve büyüklükteki girdileri daha sınırlı büyüklükte çıktılara çevrilmesini sağlar. Girdinin büyümesi sigmoid fonksiyonunun eğiminin sıfıra yaklaşmasına neden olur. Çok katmanlı ANN eğitiminde dik iniş (steepest decent) kullanılan yaklaşımlarda bu durum çok küçük gradyan adımların

oluşmasına neden olur. Global minimumdan uzakta gerçekleşebilecek bu durum algoritmanın çözümden uzakta kalmasına neden olmaktadır. Gradyan için bulunan kısmi türevi alınırken oluşan bu zararlı durumları ortadan kaldırmak için BTRBP algoritması tercih edilir. Böylece kısmi türevin büyüklüğü yerine sadece işareti ağırlık güncellemesinde yönü bulmada kullanılır. Ağırlık güncellemesi için ayrı bir değer kullanılır. Ardışık iki başarılı iterasyonda performans fonksiyonunun ağırlık değerine göre türevi aynı işarete sahipse, nöronlar için kullanılan her bir ağırlık ve bias değeri δ_{inc} değeri ile artırılarak güncellenir. Diğer taraftan ardışık iki başarılı iterasyonda performans fonksiyonunun ağırlık değerine göre türevi farklı işarete sahipse, nöronlar için kullanılan her bir ağırlık ve bias değeri δ_{dec} değeri ile azaltılarak güncellenir. Kısmi türev sıfır olduğunda ise güncelleme değeri aynı bırakılır.


Destek Vektör Makinaları (SVM)

Sinir ağırları modelinin referansında gerçekleştirilmiş SVM modeli, ANN modelinin eğitim setinde en iyi sonucu verme prensibine karşılık olarak eğitim setinde belirli bir miktar hata yapmak ancak hiç görülmemiş test setinde daha iyi performans göstermek amacını taşıyan bir yöntemdir. SVM modeli, özellikle sınıflandırma amaçlı kullanılan bir hiperdüzlem çözümdür. Öncelikle problemin farklı boyutta çözülebilecek bir hiperdüzleme taşınması ve burada çözülmesi gereklidir. Şekil 0.2’de gösterildiği gibi birbirinden farklı kümelerin maksimum marjını düşünerek birbirinden ayrıştırılmasını sağlar.

Doğrusal SVM modeli için matematiksel model:

$$y = wx - b \quad (0.14)$$

şeklinde ifade edilebilir. Burada;



Şekil 0.2 Doğrusal SVM Modeli

y : Çıkış vektörü

w : Hiperdüzlem normali

x : Girdi vektörü

b : Çizilen hattın kaydırma parametresi

olarak tanımlanır. Kullanılan eğitim setiyle marjin aralığının maksimize edilmesi, test setinde daha iyi sonuç elde etmeyi sağlar. Doğrusal olmayan bir hat ile veri setlerini ayırmak için ise Lagrange çarpanları ve Kernel fonksiyonlarından yararlanır. Bu durumda matematiksel ifade:

$$y = \sum y_j \alpha_j K(x_j, x) - b \quad (0.15)$$

şekline dönüşür. Burada, α Lagrange çarpanlarını, K ise x ile x_j arasındaki benzerlik veya uzaklığı ölçen Kernel fonksiyonunu ifade eder. Kernel fonksiyonunun seçimi SVM modeli için oldukça önemlidir.

SVM modeli, regresyon problemlerine başarılı bir şekilde uygulanabilen, yapısal risk minimizasyon temeline dayanan, yüksek genelleştirme özelliğinde, doğrusal ya da doğrusal olmayan bir makine öğrenme metodudur [88]. Bu nedenle özellikle rüzgâr tahminlerinde Kernel fonksiyonu olarak Radyal Tabanlı Kernel Fonksiyonunu (RBF) seçilmektedir. Bu fonksiyon Eşitlik (0.16)'te verilmiştir.

$$K(z_j, z_i) = \exp\left(-\lambda \|z_j - z_i\|^2\right) \quad (0.16)$$

Burada, z_j ve z_i eğitim örneklerini, λ pozitif değerdeki kernel parametresini ifade etmektedir.

Eğitim setinin karakteristiğine göre yani her bir rüzgâr santrali için uygun fonksiyonun kullanımına göre model performansı artırılabilir. Rüzgâr ve rüzgâr üretim tahminlerinde kullanılan SVM modeli için regresyon (SVR) yöntemleri kullanılmıştır. SVR yönteminde SVM'den farklı olarak eğitim seti girdileri, hiperdüzlemin normali yerine doğrusal olmayan bir fonksiyon yardımıyla daha yüksek boyutlu bir özellik düzlemine taşınır. Bu yeni özellik düzleminde doğrusal regresyon uygulanır ve parametreler bulunur.

K-means Sınıflandırma Modeli

K-means sınıflandırma modeli, bir bütün veri setini tanımlanan sayıda (K) temel bir denetimsiz yaklaşımla bölümlendiren sınıflandırma modelidir. Çok fazla verinin olduğu problemlerde her bir verinin ait olduğu sınıfı da belirleyen model sayesinde, veri seti istenen yapıda bölümlere ayrıştırılır.

K-means sınıflandırma metodu, çıkışta K tane sınıf oluşturacak şekilde gözlem değerlerini sınıflandırır [84]. Denetimsiz bir öğrenme tekniği olan K-means sınıflandırma yöntemi, K sınıf için K tane merkez değeri belirler. Merkezler arasındaki uzaklıklar olabildiğince maksimize edilirler. Veri seti içerisindeki her bir nokta en yakın sınıf merkezine atanır. Daha sonra ilk iterasyonun sonunda tüm merkez değerleri tekrar hesaplanarak güncellenir. Bu prosedür merkez değerleri daha fazla değişmeyecek ana kadar tüm iterasyonlar boyunca uygulanır. Sonuç tüm işlemlerin nihai amacı Eşitlik (0.17)'de verilen hedef fonksiyonunun minimize edilmesidir.

$$KD = \sum_{i=1}^c \sum_{j=1}^n (\|x_i - c_j\|^2) \quad (0.17)$$

burada, x_i i 'inci veriyi, c_j j 'inci sınıf merkezini, n veri sayısını ve KD ise x_i ve c_j arasındaki uzaklığı ifade etmektedir.

K-means sınıflandırma algoritması:

Örnek olarak verilen bir $X = \{x_1, x_2, x_3, \dots, x_n\}$ veri kümesi için $V = \{v_1, v_2, v_3, \dots, v_c\}$ merkez noktalar kümesini ifade etsin. Bu durumda K-means algoritması adımları şöyle olur:

- 1) Rastgele c adet sınıf için merkez değeri seç
- 2) Her bir veri için sınıf merkezlerine olan uzaklığı bul
- 3) Veriyi en yakın olduğu sınıfa ata.
- 4) Verinin eklendiği sınıf için yeni merkez değerini aşağıdaki Eşitlik (0.18) ile hesaplanır.

$$v_i = \frac{1}{c_i} \sum_{j=1}^{c_i} x_j \quad (0.18)$$

- 5) Her bir veri ile yeni bulunan sınıf merkez değerleri arasındaki uzaklığı hesapla
- 6) Herhangi bir veri sınıfı değiştiğinde 3. adımdan itibaren tekrar et. Veri sınıfları aynı kalınca dur.

Algoritma sonucunda her bir veri en yakın olduđu sınıfa atanmış ve tüm veri seti K sayıda sınıfa bölünmüş olur.

Adaptif Arttırma (AdaBoost) Modeli

Adaptif Arttırma (AdaBoost) Modeli, sınıflandırma ve regresyon problemlerinde başarılı bir şekilde kullanılan çoklu girdileri tek bir girdiye çeviren öğrenme metodudur [89]. Verideki gürültü ve aykırı örnekleri hassas bir şekilde analiz ederek, zayıf öğrencilerin kombine edilerek ve güçlü öğrencilerin elde edilmesini sağlar. Her bir iterasyon adımında bir önceki adımda bulunmuş olan toplam tahmini ile ölçülen değerler karşılaştırılarak topluluk tahmini yeni bir öğrenen tahmine uyar. Son adıma kadar topluluk tahmini MSE değerini minimize etmeye çalışır.

Bu tez çalışmasında, en küçük kare AdaBoost (LS AdaBoost) metodu regresyon için kullanılmış ve Eşitlik (0.19)'da verildiği gibi her bir adımda yeni bir öğrenene uymaya çalışır.

$$Y'(x) = Y(x) - \eta f(x) \quad (0.19)$$

burada, $Y'(x)$ topluluk değerini, $Y(x)$, gözlenen değeri, $f(x)$, x gözlem değeri için tüm zayıf öğrenenlerin toplanmış tahminini ve η öğrenme oranını ifade etmektedir. LS AdaBoost yöntemi kullanılarak birden fazla girdi verisi güçlü nihai bir çıktı verisine dönüştürülür.

EK-3 ORTA ÖLÇEKLİ HAVA TAHMİN MODELLERİ

ALADIN Modeli

ALADIN sınırlı alan modeli çalışmaları, ilk olarak Kasım 1990 yılında Meteo France'nin ARPEGE global modelinin sınırlı alan için geliştirilen versiyonunu Bulgaristan, Macaristan, Çek Cumhuriyeti, Polonya, Romanya ve Slovakya ile birlikte araştırma ve geliştirmeye açmasıyla başlanmıştır. Bundan sonraki süreçte Cezayir, Belçika, Fas, Tunus, Portekiz, Avusturya, Hırvatistan, Slovenya ve en son olarak Türkiye bu gruba katılmıştır.

ALADIN aslında, AROME, ALARO ve ALADIN modelleri ile bu modellerin başlangıç ve sonuç datalarını işlemek için gerekli araçları da içeren komple bir sistemdir. Bu araçlar arasında data asimilasyonu, ODB (Observational Database), FatoGRIB, klimatolojik dataların hazırlanması, Diagnostik parametrelerin üretilmesi de yer almaktadır.

AROME ve ALARO ise ALADIN'in hidrostatik olmayan versiyonları olup yatay çözünürlükleri sırasıyla 2.5 km ve 57 kilometredir. Bu modellerin başlangıç ve sınır koşulları ARPEGE global modelinden elde edilmektedir. Meteoroloji Genel Müdürlüğü (MGM ya da DMİ)'nde halen ALADIN modeli operasyonel olarak çalıştırılmakta olup daha sonraki süreçte ALARO ve AROME modelleri de operasyonel olarak kullanılması planlanmaktadır [90].

ALADIN yaklaşık olarak 10 km yatay çözünürlükte Kartezyen gridlerde sınırlı bir alanda çalışan biperiyodik ve hidrostatik hava tahmin modelidir [91].

WRF Modeli

Hava Tahmin ve Araştırma (Weather Research and Forecasting, WRF) modeli, operasyonel öngörüler kadar atmosferik araştırmalara yanıt verebilecek yeni nesil bir sayısal hava tahmin modelidir. Bu model birden fazla dinamik merkez koduna ve 3DVAR isimli bir veri asimilasyonu sistemine sahiptir. WRF paralel hesaplamaya olanak veren, gelişmeye açık bir yazılım mimarisi kullanmaktadır [92].

WRF, bölgesel öngörülerde geniş spektrumlu (sinoptik ve orta ölçekli) atmosferik olayların incelenmesine olanak vermektedir. Aslında model daha önce benzer amaçlarla kullanılan MM5 modelinin geliştirilerek yenilenmiş bir versiyonudur.

En önemlisi, modelin arkasında geniş bir geliştirici ve kullanıcı desteği vardır ve bu yönüyle gerçek bir kullanıcı grubu modeli niteliği taşımaktadır. Modelin geliştirilmesi, ABD National Center for Atmospheric Research (NCAR), National Oceanic and

Atmospheric Administration-National Centers for Environmental Prediction (NOAA-NCEP), Forecast Systems Laboratory (FSL), Air Force Weather Agency (AFWA), Naval Research Laboratory (NRL), University of Oklahoma, Federal Aviation Administration (FAA) gibi kuruluşların işbirliği ile gerçekleştirilmiştir. Fiziksel, sayısal ve veri asimilasyonu alanlarındaki gelişmeler, modelin hesaplama verimliliği ve esnekliği sayesinde bu araştırma grubunun desteği ile modele kolayca uygulanabilmektedir.

Modelin fiziksel ve sayısal yaklaşımları kaynak dokümanlarında bulunmaktadır. Modelin bir özelliği de hidrostatik varsayım kullanmadan orta ölçek topoğrafya etkilerini daha gerçeğe yakın temsil edebilmesidir. Ayrıca hesaplama paralel yürütüldüğü için, model alanı içinde çözünürlüğü farklı birden fazla alt-bölge seçilebilmektedir.

Hem global hem de sınırlı alan modeller tahminlerinde bir takım hatalar meydana gelmektedir. Bu hataları iki grupta toplayabiliriz

Sistemik Hatalar: Modelin gerek fiziksel parametrisasyon problemlerinden, gerek yatay çözünürlüğünün az olmasından, gerekse topografya verisinin gerçek topografyayı tam olarak ifade edememesinden dolayı meydana gelen ve süreklilik arz eden hatalardır. Bu tür hataların düzeltilmesi için modelin kendisine müdahale edilmesi gerekmektedir.

Sistemik Olmayan Hatalar: Modele giren başlangıç koşullarındaki hatalardan kaynaklanan ve devamlılık arz etmeyen hatalardır. Bu tür hataların düzeltilmesi için başlangıç verisinin asimilasyon çalışmalarıyla iyileştirilmesi gerekmektedir.

DMİ Modeli

Devlet Meteoroloji İşleri (ya da MGM) tarafından hava tahminlerinde kullanılan ve ALADIN modeli ile oluşturulan bir hava tahmin modelidir.

GFS Modeli

Global tahmin sistemi, GFS, Amerika Birleşik Devletleri Ulusal Hava Servisi (NWS) tarafından oluşturulan global hesaplama ile değişkenler analizini içeren global bir sayısal hava tahmin sistemidir [93].

Kullanılan matematiksel model günde 4 kez çalıştırılarak gelecek 16 güne kadar tahmin üretilir. Ancak tahmin zaman aralığı uzadıkça doğruluğu düşmektedir. Bu model sıklıkla kullanılan sinaptik orta ölçekli bir hava tahmin modelidir.

GFS modeli, sıcaklıktan rüzgâra ve yağıştan toprak nemine kadar çok sayıda atmosferik ve karasal veriyi içerisinde barındırır. Global olarak 16 günlük tahminlerde tüm alanlarda grid

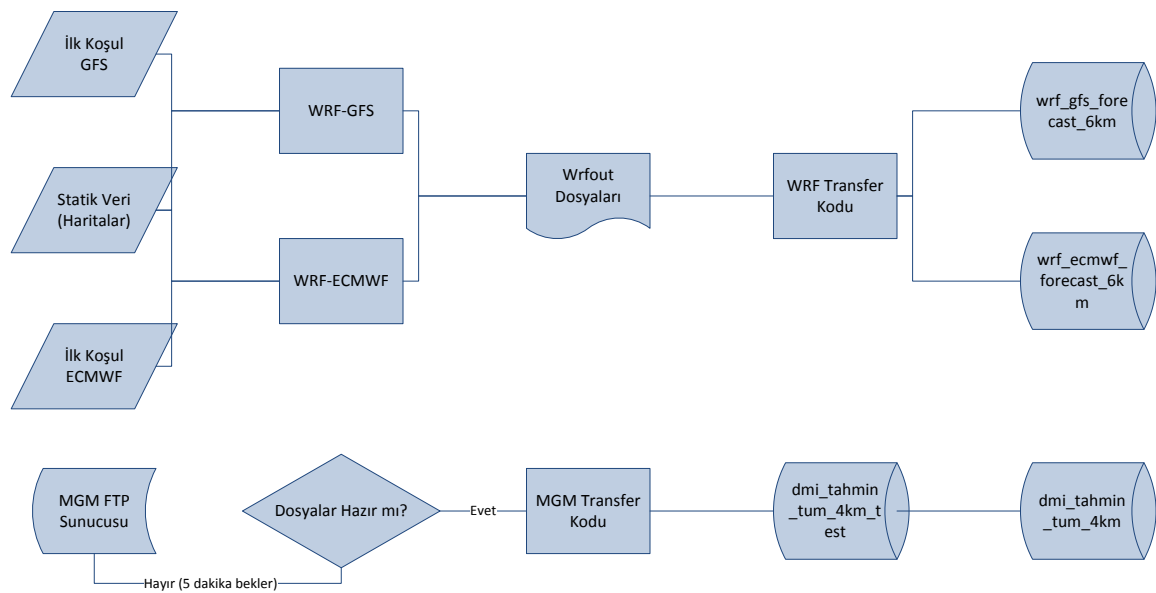
noktaları arasında temelde 18 km çözünürlük varken bu çözünürlük tahmin zaman aralığı değiştiğinde uygun çözünürlüklere getirilerek model koşturulur. Model sonuçları, MOS analizlerinde de kullanılabilir. Model sonuçları, MOS analizlerinde de kullanılabilir.

GFS tahmin modeli, 4 farklı modelin birleşimi olarak oluşturulmuş bir yapıdır. Bu alt modeller; atmosfer modeli, okyanus modeli, toprak modeli ve deniz buz modeli birlikte çalıştırılarak doğruluğu artırılmış hava durumu haritası ortaya koyarlar. Bir taraftan model analiz sonuçları ticari olarak kullanıcılara sunulurken, diğer taraftan yeni grid çözünürlükleri ve koşturma sıklıkları sürekli değiştirilerek gelişimi devam etmektedir.

ECMWF Modeli

ECMWF modeli Avrupa Orta Vadeli Hava Tahmin Merkezi Türkiye'nin de aralarında bulunduğu 17 Avrupa ülkesi tarafından 11 Kasım 1973'te kurulmuştur. Yapılan araştırma ve çalışmalar sonucu ECMWF Deterministik Modeli ortaya çıkarılmıştır ve 1 Ağustos 1979 tarihinden itibaren de operasyonel hale getirilmiştir. Model 0.25x0.25 (Yaklaşık 25km.) çözünürlükte olup küresel olarak çalışan ve 10 günlük tahminler üreten bir modeldir. Yer seviyesinden itibaren 1000, 850, 700, 500, 400, 300, 250, 200, 150 ve 100 hPa seviyelerine ait bilgiler ilk 3 güne kadar üçer saat aralıklarla, 3 günden 10 güne kadar ise 6'şar saat aralıklarla yapılmaktadır.

Sayısal hava tahmin modelleri rüzgâr gücü tahminlerinde kullanılan rüzgâr hızı, yönü, sıcaklık, basınç ve nem gibi parametrelerin elde edilmesinde kullanılmaktadır [94]. Sayısal hava tahmin modellerine ilişkin genel akış aşağıda verilmektedir (Şekil 0.3).



Şekil 0.3 Sayısal Hava Tahmin Modelleri Akış Şeması

RİTM projesindeki DMİ verileri için günlük gerçekleştirilen işlemler ve bunların detayları maddeler halinde şu şekilde özetlenebilir.

- DMİ verileri günde 4 kez oluşturulmaktadır. Her tahmin gelecekteki 48 saati kapsar.
- 00 verisi dışındaki verilerin performans düşüklüğünden dolayı sadece 00 verisi kullanılmaktadır.
- DMİ sunucuları her 5 dakikada bir kontrol edilerek yeni veri gelme durumu incelenmektedir.
- Yeni veriler RİTM sunucularına kopyalanmaktadır. 00 verisi için bu durum yaklaşık her gün 07:00'da yapılmaktadır.
- Veriler ilk olarak veri tabanında test tablosuna kaydedilmektedir.
- Bu tablodaki veriler kullanılarak tahminler yaklaşık 1 saat içerisinde tamamlanmaktadır.
- Tahminler gönderildikten sonra veriler yeni tahmin tablosuna kaydedilmektedir.

RİTM projesinde WRF-GFS verileri için günlük gerçekleştirilen işlemler ve bunların detayları maddeler halinde şu şekilde özetlenebilir.


- GFS verileri günde 4 kez oluşturulmaktadır. Her tahmin gelecekteki 48 saati kapsar.
- Her dört veri seti de tahminlerde kullanılarak tahminler güncellenmektedir.
- RİTM sunucuları zamansal akışta belirtilen saatlerde veri indirimlerine başlamaktadır.
- Yeni veriler karşı sunucularda bulunması halinde RİTM sunucularına kopyalanmaktadır.
- İndirilen veriler WRF programında kullanılarak sayısal hava tahminleri elde edilmektedir. Sonuçlar veri tabanı tablosuna yazılmaktadır.
- Bu tablodaki veriler kullanılarak tahminler yaklaşık 40 dakika içerisinde tamamlanmaktadır.

WRF-ECMWF verileri için günlük gerçekleştirilen işlemler ve bunların detayları maddeler halinde şu şekilde özetlenebilir.


- ECMWF verileri günde 1 kez oluşturulmaktadır. Her tahmin gelecekteki 48 saati kapsar.
- RİTM sunucuları zamansal akışta belirtilen saatte veri indirimlerine başlamaktadır.

- Yeni veriler karşı sunucularda bulunması halinde RİTM sunucularına kopyalanmaktadır.
- İndirilen veriler WRF programında kullanılarak sayısal hava tahminleri elde edilmektedir. Sonuçlar yeni veri tabanı tablosuna yazılmaktadır.
- Bu tablodaki veriler kullanılarak tahminler yaklaşık 40 dakika içerisinde tamamlanmaktadır.


EK-4 SANTRALLERİN RÜZGÂRGÜLLERİ




Şekil 0.4 WPP1, WPP2, WPP3, WPP4, WPP5 ve WPP6 santralleri için rüzgârgülleri




Şekil 0.5 WPP7, WPP8, WPP9, WPP10, WPP11 ve WPP12 santralleri için rüzgârgülleri



Şekil 0.6 WPP13, WPP14, WPP15, WPP16, WPP17 ve WPP18 santralleri için rüzgârgülleri




Şekil 0.7 WPP19, WPP20, WPP21, WPP22, WPP23 ve WPP24 santralleri için rüzgârgülleri




Şekil 0.8 WPP25 santrali için rüzgârgülü


EK-5 SANTRALLERİN NWP ve RWM RÜZGÂRGÜLÜ KARŞILAŞTIRMASI




Şekil 0.9 NWP ve RWM rüzgârgülleri
 (a) WPP1' NWP (b) WPP1' RWM (c) WPP2' NWP (d) WPP2' RWM
 (e) WPP3' NWP (f) WPP3' RWM



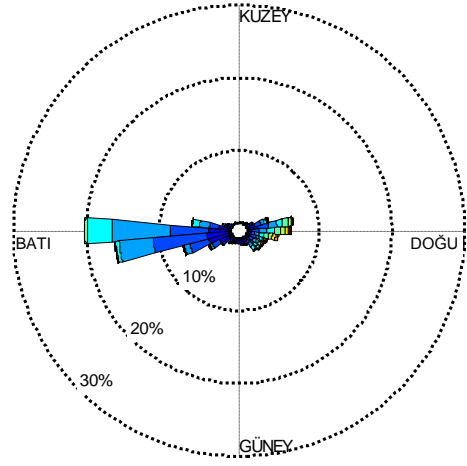
(a)




(b)




(c)



(d)




(e)




(f)

Şekil 0.10 NWP ve RWM rüzgârgülleri
 (a) WPP4' NWP (b) WPP4' RWM (c) WPP5' NWP (d) WPP5' RWM
 (e) WPP6' NWP (f) WPP6' RWM




Şekil 0.11 NWP ve RWM rüzgârgülleri
 (a) WPP7' NWP (b) WPP7' RWM


EK-6 SANTRALLERİN RÜZGÂR-GÜÇ EĞRİLERİ




(a)




(b)




(c)



(d)




(e)

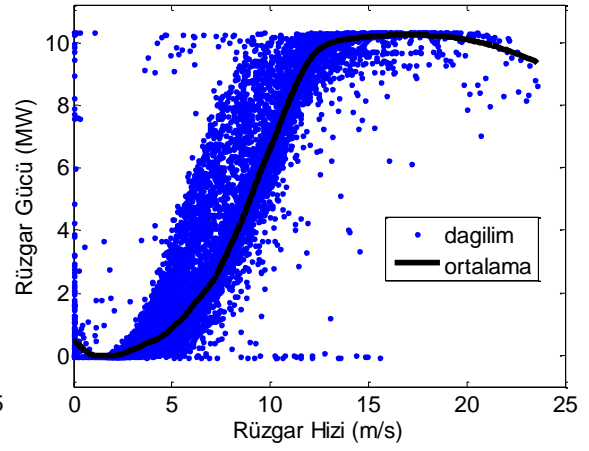


(f)


Şekil 0.12 WPP1', WPP2' ve WPP3' santralleri için NWP ve RWM rüzgâr-güç eğrileri
(a)WPP1' NWP (b) WPP1' RWM (c) WPP2' RWM (d) WPP2' RWM
(e) WPP3' NWP (f) WPP 3' RWM




(a)




(b)




(c)



(d)




(e)



(f)

Şekil 0.13 WPP4', WPP5' ve WPP6' santralleri için NWP ve RWM rüzgâr-güç eğrileri
 (a)WPP4' NWP (b) WPP4' RWM (c) WPP5' RWM (d) WPP5' RWM
 (e) WPP6' NWP (f) WPP6' RWM



Şekil 0.14 WPP7' santrali için NWP ve RWM rüzgâr-güç eğrileri
(a)WPP7' NWP (b) WPP7' RWM

ÖZGEÇMİŞ

Kimlik Bilgileri

Adı Soyadı : SERKAN BUHAN
Doğum Yeri : Tatvan
Medeni Hali : Evli
E-posta : serkan.buhan@tubitak.gov.tr
Adres : TÜBİTAK MAM EE Ankara Birimi 06531 ODTÜ Çankaya/ANKARA

Eğitim

Lise : Tarsus Cumhuriyet Lisesi (YADAL), MERSİN
Lisans : Anadolu Üniversitesi İşletme Bölümü (Açıköğretim-İkinci Üniversite),
ESKİŞEHİR, 2005
Lisans : Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü,
ANKARA, 2005
Yüksek Lisans: Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü,
ANKARA, 2009
Doktora : Hacettepe Üniversitesi Elektrik ve Elektronik Mühendisliği Bölümü,
ANKARA

Yabancı Dil ve Düzeyi

İngilizce : Çok İyi

İs Deneyimi

2005- 2005 : EMES Elektromekanik Sis. Ltd. Şti. Elektronik Mühendisi, ANKARA
2006- ... : Uzman Araştırmacı, TÜBİTAK MAM Enerji Enstitüsü, ANKARA

Deneyim Alanları

Yenilenebilir Enerji Sistemleri, Rüzgâr Gücü Tahminleri, Güç Kalitesi, Güç Elektroniği

Tezden Üretilmiş Projeler ve Bütçesi

-

Tezden Üretilmiş Yayınlar

S. Buhan, I. Cadirci, “Multi-Stage Wind-Electric Power Forecast by Using a Combination of Advanced Statistical Methods,” *IEEE Transactions on Industrial Informatics*, vol. 11, no. 5, pp.1231-1242, Oct. 2015.

S. Buhan, Y. Ozkazanc, I. Cadirci, “ Wind Pattern Recognition and Reference Wind Mast Data Correlations with NWP for Improved Wind-Electric Power Forecasts,” *IEEE Transactions on Industrial Informatics*, Major Revision.

Tezden Üretilmiş Tebliğ ve/veya Poster Sunumu ile Katıldığı Toplantılar

-